

Sveučilište u Zagrebu

Filozofski fakultet

Odsjek za sociologiju

Diplomski rad

MREŽNA ANALIZA MOBILNOSTI HRVATSKIH VISOKIH
UČILIŠTA U OKVIRU PROGRAMA ERASMUS+

Kandidatkinja:

Domina Vusio

Mentorica:

doc.dr.sc. Ksenija Klasnić

Zagreb, rujan 2017.

Sadržaj

1. Uvod.....	3
2. Ciljevi i svrha.....	4
3. Teorijski koncept	5
3.1. Izazovi u istraživanju akademske mobilnosti.....	5
3.2. Mobilnost iz nacionalne, institucionalne i individualne perspektive	8
3.3. Trendovi u međunarodnoj mobilnosti i Erasmus programu.....	12
3.4. Topologija mreže mobilnosti	14
4. Hipoteze	16
5. Metodologija	16
6. Rezultati i rasprava.....	17
6.1. Osnovne karakteristike mreže	18
6.2. Analiza na razini zemalja	22
6.3. Analiza na razini institucija.....	32
7. Zaključak	40
Literatura	43
Prilozi	46
Sažetak	53
Abstract	54

1. Uvod

U društvu koje teži k tome da bude pozicionirano kao društvo znanja, te da temelji svoju ekonomiju na razvoju visoko obrazovane radne snage, povećanje, ali i razumijevanje akademske mobilnosti je od krucijalnog značaja. Kako bi funkcioniralo, društvo znanja zahtijeva slobodan tok znanja, studenata, nastavnika i istraživača, koji „tvore i odražavaju šire međunarodne odnose u produkciji, transferu i cirkulaciji znanja“ (Shields, 2013, 609). Uz ekonomske prednosti akademske mobilnosti treba istaknuti i sociokulturnu važnost mobilnosti za pitanje europske integracije i dijeljenje europskih kulturnih vrijednosti. González i dr. (2011) ističu mobilnost studenata kao glavni mehanizam za poticanje stvaranja europskog identiteta i državljanstva. Nadalje, promocija mobilnosti je četvrta od deset smjernica Bolonjske deklaracije, te kasnijih priopćenja (Prag, 2001; Berlin, 2003), s ciljem ostvarenja Europskog prostora visokog obrazovanja do 2010. godine. Diskurs Europske komisije uključuje niz ideja koje nastoje promicati osjećaj "eupejstva" kroz mobilnost. Umjesto da pristupa akademskoj mobilnosti u smislu privlačenja ili zadržavanja osoba u jednoj nacionalnoj državi, taj diskurs je usmjeren prema regionalnoj konkurentnosti i naglašava integraciju europske regije kao cjeline kroz mobilnost. U ovom diskursu, promocija "europskog" pripadanja, svijesti, građanstva i znanja se zasniva na mobilnost izvan granica pojedinih europskih nacionalnih država, ali se ipak temelji na izgradnji omeđene Europe (Fahey i Kenway, 2010, 569). Europska komisija Erasmus mobilnost vidi kao instrumentalnu u europeizaciji država članica, ne samo kroz razvoj europske dimenzije, već i kroz razvoj interkulturalnih kompetencija, koje se smatraju neophodnim za gospodarski razvoj u globaliziranom svijetu (Sackmann prema Breznik i dr., 2013, 1372).

Akadska mobilnost ima snažnu pozitivnu ulogu u promicanju mira i međusobnog razumijevanja, bogatije kulture i razvoja ličnosti, povećanje akademske kvalitete, tehnoloških inovacija, ekonomskog rasta i društvenog dobrostanja. No, brojni autori ističu kako može imati i negativne posljedice poput odljeva mozgova (eng. *brain drain*) (Teichler, 2015; Van der Wende, 2015). Erasmus mobilnost može prijeći u privremenu ili trajnu migraciju kroz period od 5 godina koje slijede iza početne razmjene. Bracht i suradnici (2006) su utvrdili kako je vjerojatnije da će bivši Erasmus studenti (18%) i akademski djelatnici (9%) raditi u inozemstvu nego njihovi ne mobilni kolege. Trajna migracija ne predstavlja problem sama po sebi, no može dovesti do koncentracije znanja i kvalificirane radne snage u žarištima s visokim ulaganjima u znanost. Posljedica

toga je prekvalificiranost radne snage u područjima s visokim ulaganjima, te neispunjena potražnja za kvalificiranom radnom snagom u područjima s manjim ulaganjima. Van der Wende (2015) to naziva vertikalnom neusklađenošću, te upozorava kako će „u roku od deset godina doći do negativne ravnoteže između ponude i potražnje za talentom u najmanje 12 europskih zemalja, među kojima su i najveća europska gospodarstava“ (Van der Wende, 2015, S77). Sve je jasnije kako je suradnja između zemalja i visokih učilišta nužan uvjet za buduće blagostanje Europe, stoga Erasmus mobilnost studenata i akademskog osoblja, s temeljnim fokusom na transnacionalnu akademsku suradnju i razvoj vještina, predstavlja ključan element u strategiji Europa 2020 za pametan, održiv i inkluzivan rast (Europska komisija, 2010).

2. Ciljevi i svrha

Cilj ovog rada je pružiti točan prikaz trendova i obrazaca četiriju tipova mobilnosti visokih učilišta (studentske mobilnosti u svrhu studijskog boravka, studentske mobilnosti u svrhu stručne prakse, mobilnosti akademskog osoblja u svrhu podučavanja, te mobilnosti akademskog osoblja u svrhu osposobljavanja), kao i ukupne mobilnosti u okviru programa Erasmus +. Glavni uvjet za razmjenu studenata jest taj da proces treba podjednako doprinositi objema stranama uključenim u razmjenu, stoga je težnja za ravnotežom između dolaznih i odlaznih tokova prirodna orijentacija Erasmus programa. Uz prikaz dolaznih i odlaznih tokova mobilnosti na razini zemalja koje sudjeluju u programu, posebno ćemo se osvrnuti na dolazne i odlazne tokove mobilnosti, te poziciju Hrvatske u mreži.

Nadalje, korištenjem mrežne analize na razini visokih učilišta, cilj nam ispitati topologiju mreže Erasmus+ mobilnosti i njene strukturne karakteristike. Zanima nas da li takva mreža odražava svojstva nesrazmjerne mreže koja pak možemo pronaći u stvarnom svijetu na brojnim primjerima velikih mreža, odnosno odvija li se povezivanje visokih učilišta u Erasmus programu po principu „bogati postaju bogatiji“. Također, želimo vidjeti da li strukturni prestiž visokih učilišta, mjeren brojem različitih partnera i brojem dolaznih mobilnosti, odgovara društvenom prestižu koji visoka učilišta uživaju. Ispitujući topologiju mreže, posebnu pažnju planiramo pridati centralnim visokim učilištima u mreži, kao i strukturnoj ekvivalenciji i poziciji hrvatskih visokih učilišta u istoj.

Ovim radom želimo doprinijeti znanju o manje istraživanom tipu mobilnosti u Europi – privremenoj mobilnosti ili mobilnosti u svrhu stjecanja ECTS bodova, u kojoj upravo Erasmus program ima velik udio. Namjera je prikazati mobilnosti unutar Erasmus programa, na razini zemalja i visokih učilišta kao aktera mreže, fokusirajući se ne samo na njih, već i na odnose među njima, njihovu ugrađenost u mrežu i povezanost, što nam omogućuje mrežni pristup.

3. Teorijski koncept

3.1. Izazovi u istraživanju akademske mobilnosti

Najviše pažnje u istraživanju akademske mobilnosti posvećeno je studentskoj mobilnosti, no iako se studentska mobilnost mnogo istražuje, kvaliteta međunarodnih baza podataka je upitna. Tri najbitnije slabosti međunarodnih baza podataka po Teichleru su: dominacija podataka o stranim studentima (četvrtina stranih studenata zapravo živi u zemlji dulje vrijeme), ne radi se razlika između privremene mobilnosti i mobilnosti u svrhu stjecanja kvalifikacije, te ne uključuju većinu privremenih studenata (Teichler, 2015, 13). Problem je u tome što međunarodna studentska mobilnost može imati mnogo oblika, od upisa na cjelokupne studije u različitim zemljama, do upisa na različite jezične programe usmjerene na strance koji ne odgovaraju strogo tradicionalnim programima koji se nude domaćim studentima. Značajan dio studentske mobilnosti također se pojavljuje kao dio multilateralnih programa poput Erasmus i Nordplusa u nordičkim i baltičkim zemljama.

Prvo, razlika može biti između mobilnosti u svrhu stjecanja kvalifikacije (eng. *degree mobility*) ili mobilnost u svrhu stjecanja ECTS bodova (eng. *credit mobility*), koja se često naziva i privremenom mobilnosti (eng. *short-term mobility*), pri čemu je prva uobičajena forma kretanja studenata preko međunarodnih granica diljem svijeta, a potonja prevladavajući oblik studentske mobilnosti u Europi. Glavna razlika između dva oblika prema Van Molu (2014) jest ta što su studenti koji su mobilni u svrhu stjecanja bodova i dalje upisani na matična visoka učilišta tijekom studijskog boravka u inozemstvu. Osim toga, kako su međunarodne razmjene obično organizirane u okviru institucionaliziranih programa razmjene, studenti ne moraju platiti školarinu visokom učilištu na koje dolaze. Stručnjaci procjenjuju kako Erasmus studenti čine trećinu svih privremeno mobilnih studenata u Europi. Teichler (2015) ističe kako dostupna analiza privremene mobilnosti pokazuje kako postoji potreba za definiranjem praga perioda

mobilnosti: treba li se studentska mobilnost smatrati značajnim iskustvom samo ukoliko je u drugoj zemlji proveden određeni minimum vremena? Često se semestar ili tromjesečni boravak smatra takvim minimumom. Nadalje, potrebno je odrediti aktivnosti koje spadaju u mobilnost: trebaju li se ubrajati samo mobilnosti za redovne studije ili i za staž, ljetne škole, tečajeve jezika i sl. (Teichler, 2015, 14).

Nadalje, Teichler (2015) pravi razliku između horizontalne i vertikalne mobilnosti. Vertikalna mobilnost premješta studente iz akademski i često ekonomski nepovoljnijih zemalja i institucija u pogodnije. To se temelji na nadi da je kvaliteta nečije kompetencije znatno pojačana takvim skokom prema gore, a prilagodba zemlji domaćinu i instituciji je imperativ. U horizontalnoj mobilnosti, studenti su mobilni između zemalja i institucija slične akademske razine: učenje iz značajnih suprotnosti je cilj, a ne skok prema gore. Teichler smatra da dostupne informacije ukazuju da većina vertikalno mobilnih studenata studira u inozemstvu za vrijeme cjelokupnog studijskog programa, dok se većina horizontalno mobilnih studenata odlučuje za privremeno studiranje u drugoj državi (Teichler, 2015, 12). Van Mol (2014) ističe da iako je privremena mobilnost ili mobilnost u svrhu stjecanja bodova prevladavajući oblik mobilnosti u Europi, intraeuropska mobilnost nije samo horizontalna već donekle i vertikalna zbog sudjelovanja prestižnih institucija poput Oxforda.

Naposljetku, razlikujemo slobodnu i programsku mobilnost. Iako je teško utvrditi u detalje što čini program (a što ne), postoje neke široke karakteristike zajedničke svima njima. Za razliku od "slobodne" mobilnosti, mobilnost unutar programa je:

1. *Organizirana* - studenti sudjeluju u nečem što bismo mogli nazvati "paket-aranžman", a ne individualni turizam;
2. *Financirana* - studenti dobivaju školarinu za pokrivanje dijela ili ukupnog troška mobilnosti.
3. *Privremena* - studenti se premještaju na ograničeno vremensko razdoblje s "matične ustanove" na "ustanovu primateljicu" u inozemstvu. Programska mobilnost je oblik mobilnosti u svrhu stjecanja bodova (Wächter i Wuttig, 2011, 162). Važno je naglasiti kako podaci programske mobilnosti nisu lako usporedivi s podacima koji se odnose na "slobodnu" mobilnost. "Slobodna" mobilnost može se smatrati, u granicama, kao izraz sklonosti mobilnih studenata. To nije nužno slučaj u programskoj mobilnosti. Prema Wächter i Wuttig (2011) u programskoj mobilnosti barem tri faktora oblikuju obrasce mobilnosti. Prvo, izbor studenata očito igra ulogu i ovdje, kao posljedica stupnja privlačnosti različitih odredišnih zemalja. Drugo, sposobnost i spremnost određene

zemlje i njenih institucija da prime studente koji tu žele studirati važan je faktor. Treće, programski pružatelji upliću se pokušavajući ostvariti ono što smatraju idealom studentskih tokova, primjerice u obliku reciprociteta. Prvi faktor odnosi se i na "slobodnu" mobilnost također, drugi može, no treći nikako (Wächter i Wuttig, 2011, 163).

Mobilnost istraživača i akademskog osoblja manje je istraživana. Podatci o međunarodnoj mobilnosti akademika još su oskudniji i nepotpuniji od podataka o studentskoj mobilnosti (Tremblay, 2008; Teichler 2011; Rostan i Höhle, 2014). U sustavu visokog obrazovanja razlikuje se obrazovni sistem s jedne strane i istraživački s druge. Akademsko osoblje je kategorija u sustavu institucija tercijarnog obrazovanja, dok su u istraživačkom sustavu „istraživači“ ili „znanstvenici“ primarna kategorija u prikupljanju podataka. Teichler naglašava kako je većina dostupnih podataka prikupljena u okviru kategorije istraživača unutar istraživačkog sustava, te nije kompatibilna s onim o akademskom osoblju u visokom ili tercijarnom obrazovanju (Teichler, 2011, 117). Situacija je dodatno zakomplicirana postojanjem višestrukih oblika mobilnosti akademskog osoblja, od kratkoročnih mobilnosti od nekoliko dana ili tjedana do mobilnosti u trajanju od jedne godine i više (Tremblay, 2008, 245). Teichler (2011) navodi šest mogućih razloga manje istraživanosti mobilnosti akademskog osoblja u odnosu na mobilnost studenata:

- broj studenata koji odlaze na mobilnost je značajno veći od broja mobilnog osoblja (u EU-27 zemljama u 2003./2004. akademskoj godini omjer je bio 16:1)
- međunarodna mobilnost i dalje ne predstavlja uobičajenu opciju za akademsko osoblje (u svrhu doktorskog obrazovanja ili kratkog perioda donekle, ali ne i dulja razdoblja u svrhu održavanja nastave)
- mobilnost akademskog osoblja rjeđe je sastavni dio zajedničkog strateškog napora pojedinih visokih učilišta, primjerice u okviru strategija internacionalizacije
- izvješća o internacionalizaciji u slučaju istraživačke funkcije ne fokusiraju se na mobilnost, već na krajnje ishode – zajedničke publikacije, citiranost ili patente
- na studentsku mobilnost se gleda kao na pozitivnu, no na mobilnost osoblja se nekada gleda kao na nešto nepoželjno, te ju se povezuje s odljevom mozgova
- informacije dostupne o mobilnosti akademskog osoblja i povezanih pitanja nekompletne su i nekoherentne.

3.2. Mobilnost iz nacionalne, institucionalne i individualne perspektive

Erasmus program započeo je 1987./1988. akademske godine. U prvoj godini programa, mobilnost je ostvarilo 3 244 studenata iz 11 zemalja sudionica. Danas u programu razmjene sudjeluju visoko obrazovne institucije iz 33 zemlje, a broj sudionika stalno raste. Oko 4% ukupne studentske populacije zemalja koje sudjeluju u programu sudjelovalo je u razmjeni u okviru programa (European Commission, 2012). Erasmus program glavni je instrument EU za poticanje mobilnosti studenata i akademskog osoblja, a sama motivacija za pokretanjem programa prvenstveno je politička – „želja za postizanjem veće kohezije između zemalja članica EU kroz međusobne veze i bolje razumijevanje između budućih lidera“ (Bode i Davidson, 2011, 71). Sudjelovanje u programu bi trebalo mlade Europljane dovesti u kontakt jedne s drugima, što bi trebalo dovesti do razvoja osjećaja europskog identiteta kao korisnog ishoda. Drugo, Erasmus boravak bi trebao promovirati mobilnosti unutar Europe, te povećati vjerojatnost budućeg migracijskog ponašanja studenata u njihovim budućim karijerama (Van Mol, 2014, 14).

Na razini zemalja, prednosti mobilnosti predstavljene su kroz povećanje međunarodne kompetitivnosti, stimulaciju tržišta rada i podršku interakciji građana različitih zemalja. U današnjem okruženju ljudski kapital se smatra vitalnim za osiguranje gospodarskog prosperiteta, stoga postoji žestoko natjecanje između zemalja i svjetskih regija za privući najbolje i najpametnije na tržištu rada. Visoko obrazovanje je postalo ključni igrač u osiguranju gospodarskog razvoja i rasta inovacijskog sustava, pošto se smatra potrebnim za osiguranje pružanja ljudskog kapitala, poticanje znanstvenih istraživanja koja bi mogla služiti u ekonomske svrhe, te kao rezultat i pružanja klica za razvoj novih firmi (Dahlgren i dr. prema Van Mol, 2014, 28). U okviru nacionalnih sustava, rang-ljestvice su potaknule želju za visoko rangiranim visokim učilištima i kao simbolima nacionalnog postignuća i prestiža i kao pokretača ekonomije zasnovane na znanju (Marginson i van der Wende, 2009, 123).

Za visoka učilišta pak, visoka razina odlaznih i dolaznih mobilnosti znak je prestiža i kvalitete posebice danas kada je internacionalizacija jedan od važnijih indikatora svih svjetskih rang-ljestvica visokih učilišta (Souto-Otero i dr., 2013, 70). Pozicija na međunarodnim rang-ljestvicama djeluje i kao *push* i *pull* faktor. U očima međunarodnih studenata, institucije svjetske klase često djeluju kao signal za ukupnu kvalitetu cjelokupnog visokoobrazovnog sustava. No, te visoko obrazovne institucije svjetske klase koncentrirane su u malom broju zemalja, a ta koncentracija djeluje kao

magnet za najbolje studente zemalja koje nisu u stanju priuštiti visoko obrazovanje na standardu svjetske klase. Istraživanja perspektivnih mladih studenata pokazuju kako je reputacija osnovni pokretač tokova mobilnosti (Tremblay, 2008, 254). Žarišta privlače najveću koncentraciju mobilnih akademika. Konkretno, većinu doktorskog obrazovanja osiguravaju relativno malen broj ustanova diljem svijeta. Ova sposobnost za privlačenje talenata iz cijelog svijeta na vrlo konkurentnoj osnovi omogućava ovim institucijama da dodatno ojačaju svoje kapacitete, a kako su potaknuti i kroz rang-ljestvice, i njihov ugled. U tom smislu, trenutna geografija također može biti vodilja buduće mobilnosti i može dovesti do još veće koncentracije između, pa čak i unutar tih regija. Drugim riječima, osim ako se ne ulože dodatni napor za izgradnju kapaciteta na drugim mjestima, trenutne struje mobilnosti imaju tendenciju da snažno preferiraju etablirane institucije u ograničenom broju svjetskih regija (Van der Wende, 2015, S70/S71). Kako bi uspjela, visoka učilišta usvajaju institucionalne politike i strategije koje optimiziraju njihove pozicije na rang-ljestvicama visokih učilišta, što dodatno potiče natjecanje za vodećim istraživačima i najboljim mladim talentima. Rang-ljestvice visokih učilišta pojednostavljaju složen svijet visokog obrazovanja u dva područja od velikog javnog i privatnog značaja. One naglašavaju vertikalne razlike među institucijama i državama; odnosno razlike u moći i autoritetu, te zamagljuju horizontalne razlike, one po pitanju tipa i svrhe (Marginson i van der Wende, 2009, 122). Uspoređujući najpoznatije rang-ljestvice i njihove metodologije, Usher i Savino (2007) zaključuju kako su različite rang-ljestvice potaknute u različite svrhe, a karakteriziraju ih različite predodžbe o tome što čini kvalitetu visokog učilišta, i proizvoljni karakter pondera koji se koriste u izgradnji indeksa kojim istu mjere. Mogući razvoj je da se, u nedostatku politike koja bi ojačala raznolikost na drugi način, oslabi pozicija ne-istraživačkih institucija i potakne evolucija unificiranijih vertikalno diferenciranih sustava (Marginson i van der Wende, 2009, 128). Istovremeno, učenje drugog jezika - engleskog ili nekog drugog naširoko govorenog jezika - često je motivacija za studiranje u inozemstvu, stoga, zemlje čiji se nastavni jezik naširoko govori i čita (primjerice engleski, francuski, njemački) dominiraju kao destinacija stranih studenata, bilo u apsolutnim ili relativnim brojevima (Tremblay, 2008, 252).

Na individualnoj razini, jedan od ciljeva Erasmus studentske mobilnosti je povećanje zapošljivosti i predispozicija za prelazak granica u profesionalnom životu, razvojem europskog jedinstvenog tržišta rada (Papatsibas prema Rodrigues, 2012, 3). Uz povećanu kompetitivnost na tržištu rada, Souto-Otero i dr. (2013) ističu i dobrobit

mobilnosti za osobni razvoj. Mobilnost pojedinaca preko granica omogućuje izravnije interkulturalne interakcije s lokalnim stanovništvom u zemlji domaćinu, i intenzivnije međunarodno iskustvo (Tremblay, 2008, 241). Prema Jansonu i suradnicima, studiranje u drugoj zemlji ima pozitivan utjecaj na proces učenja kod studenata i razvoj njihovih kompetencija, ponajprije kroz:

- stjecanje akademskog znanja u područjima koja se ne podučavaju na matičnim institucijama;
- doživljaj i prikupljanje terenskog znanja o ekonomiji, društvu i kulturi zemlje u kojoj se mobilnost ostvaruje;
- uspješno proučavanje područja znanja koja su uistinu međunarodna, poput međunarodnog prava;
- učenje međunarodno komparativnog pristupa;
- širenje horizonta i refleksije kroz iskustvo kontrastnih zemalja, kultura i sl
- stjecanje internacionalnih ili interkulturalnih komunikacijskih tehnika, primjerice stranog jezika (Janson i dr., 2009, 25).

Iznenadjujuće, nema puno pomoći od teorijskih okvira da objasne studentske motivacije i barijere privremenoj mobilnosti. Souto-Otero i suradnici (2013) dio objašnjenja pronalaze u tome da većina većih istraživanja o mobilnosti u svrhu stjecanja bodova ima specifičan fokus na poboljšanje prakse a ne na teorijski razvoj, a dio objašnjenja je u tome da se većina postojećih istraživanja uklapa se u okvir izgrađen oko *push* i *pull* faktora za međunarodnu mobilnost u svrhu stjecanja kvalifikacije. *Push* faktori djeluju unutar zemlje domaćina potičući studenta da se odluči studirati van, a *pull* faktori djeluju na razini zemlje primateljice kako bi učinili tu zemlju što privlačnijom u odnosu na druge potencijalne destinacije (González; Mesanza, i Mariel, 2011, 418). Kombinacija obiju sila objašnjava međunarodnu mobilnost studenata. Van Hoof i Verbeeten (2005) pokazali su da su tri najvažnija razloga za studiranje u inozemstvu identificirana od strane skupine mobilnih preddiplomskih studenata: dobiti priliku da žive u drugoj kulturi, putovanje i specifične privlačnosti odabrane zemlje. Deakin (2014) ističe kako je motivacija studenata za mobilnost u svrhu stručne prakse različita od motivacije studenata za mobilnost u svrhu studijskog boravka. Pri tom ističe percepciju veće konkurentnosti na tržištu rada kao glavni faktor.

Postoji više *push* i *pull* faktora koji mogu utjecati na doktorsku i postdoktorsku mobilnost, i iako su odluke o mobilnosti često kompleksne, također su često pod utjecajem kvalitete znanstvenog tržišta rada u matičnoj zemlji i potencijalnim zemljama

domaćinima, kao i reputacijom prihvatne institucije ili istraživačke grupe (Van der Wende, 2015, S75). No, percepcija kvalitete je najrelevantnija za studente visokih prihoda, i postignuća, i općenito na poslijediplomskoj razini (Clarke, 2007).

Mobilnost nastavnog osoblja u okviru Erasmus programa ne služi primarno profesionalnom razvoju samih nastavnika. Umjesto toga, očekuje se da će njihova mobilnost doprinijeti razvoju studenata. Osim toga, očekuje se da nastavnička mobilnost pridonese razvoju baze znanja odjela, kao i poboljšanje kurikuluma, kako na matičnoj ustanovi, tako i na ustanovi domaćinu.

Ipak, držanje nastave, ali i druge aktivnosti povezane s Erasmus programom utječu na poboljšanje kompetencija mobilnost osoblja (Janson i dr., 2009, 121). U istraživanju Janson i suradnika (2009) više od pola profesora koji su bili mobilni je izjavilo kako im je to iskustvo poboljšalo međunarodno i interkulturalno razumijevanje, da su se upoznali s metodama koje se ne koriste na matičnoj ustanovi, da su poboljšali svoje istraživačke kontakte te imaju češće međunarodne kolaboracije. Što se tiče faktora koji utječu na mobilnost akademskog osoblja. Rostan i Höhle (2014) razlikuju faktore na više razina. Na makro strukturalnoj razini, međunarodna podjele rada, međunarodni odnosi središnjih i perifernih zemalja, povijesne prekretnice, gospodarski rast i nacionalna ulaganja u istraživanje i razvoj, funkcioniranje nacionalnih akademskih tržišta rada i sustavi visokog obrazovanja, nacionalne ili regionalne politike migracije i natjecanje za visoko kvalificiranom radnom snagom, te jezik i jezično područje su prepoznati kao faktori koji podrivaju ili potiču akademsku mobilnost. Na mikro institucionalnoj razini, pažnja je posebno usmjerena na karakteristike visokih učilišta, znanstvenih disciplina i istraživačkih aktivnosti, dok se na individualnoj razini, osobne značajke, vještina i motivacija znanstvenika, faza karijere, kao i opseg i priroda društvenih mreža u kojima su ugrađeni, (npr obiteljske veze i prijateljstva) i prethodno studijsko iskustvo u inozemstvu, smatraju faktorima koji utječu na odluku akademskog osoblja da postanu međunarodno mobilni (Rostan i Höhle, 2014, 87).

U mnogo čemu što studija Janson i suradnika (2009) ispituje, ispitanici iz središnjih i istočnoeuropskih zemalja ističu više profesionalne vrijednosti u podučavanju u okviru Erasmus programa od ispitanika zapadnoeuropskih zemalja. U tom smislu autori zaključuju kako Erasmus izgleda igra veću ulogu za zemlje središnje i istočne Europe, koje se odmiču od onoga što se nazivalo "zemlje u tranziciji" ka ravnopravnim partnerima u Europi (Janson i dr., 2009, 151). Uspoređujući rezultate prethodno objavljenih studija Teichler i Janson (2007) dolaze do zaključka kako i bivši Erasmus studenti iz srednje i

istočnoeuropskih zemalja značajno češće prijavljuju veću profesionalnu vrijednost privremene mobilnosti od bivših Erasmus studenata iz zapadnoeuropskih zemalja. U zemljama srednje i istočne Europe iskustvo studiranja vani je, zaključuju, i dalje ekskluzivno iskustvo, te osigurava višu profesionalnu nagradu (Teichler i Janson, 2007, 494).

3.3. Trendovi u međunarodnoj mobilnosti i Erasmus programu

Često u publikacijama koje tematiziraju međunarodnu akademsku mobilnost možemo pročitati o porastu apsolutnih brojeva stranih studenata diljem svijeta. Izgleda impresivno napomenuti da je ova brojka je porasla sa 300 000 u 1950. na više od 4 milijuna u 2010. Rast međunarodne studentske mobilnosti značajan je sam po sebi, ali kada se stavi u perspektivu odgovarajućeg rasta upisa u tercijarni stupanj obrazovanja. Tremblay ističe kako je u OECD zemljama, broj stranih studenata rastao je puno brže od ukupnog broja upisanih studenata između 2000. i 2005., sa rastom od 49% stranih studenata naspram 21% ukupno upisanih (Tremblay, 2008, 243). Ipak noviji podatci ukazuju kako se udio stranih studenata u odnosu na sve studente diljem svijeta nije toliko povećao iznad 2% (Teichler, 2015, 13).

Po udjelu stranih studenata upisanih u tercijarnu razinu obrazovanja ističe se Australia, Belgija, Francuska, Novi Zeland, Švicarska i Ujedinjeno Kraljevstvo, koji imaju najviše kozmopolitske kampuse, s više od jednog stranog studenta na deset upisanih u 2005. Suprotno tome međunarodni studenti predstavljaju manje od 3% upisanih u Čileu, Finskoj, Grčkoj, Japanu, Koreji, Norveškoj, Poljskoj, Rusiji, Sloveniji i Španjolskoj (Tremblay, 2008, 244). Veći dio ovih statistika čine studenti mobilni u svrhu stjecanja kvalifikacije, a rezultati istraživanja pokazuju kako je mobilnost u svrhu stjecanja kvalifikacije dio kretanja ljudi iz manje razvijenih u razvijenije zemlje, no status engleskog jezika također ima utjecaj na mobilnost (Rostan i Höhle, 2014, 89).

Proučavajući tokove međunarodno mobilnih studenata, Shields (2014) ističe kako Ujedinjeno Kraljevstvo, Francuska i Njemačka zauzimaju centralnu poziciju u Europskom prostoru visokog obrazovanja (eng. *European Higher Education Area – EHEA*), bilježeći visok studentski protok s mnogim drugim zemljama. No, dolazi do saznanja kako je broj dolaznih i odlaznih studenata više balansirao, iako i dalje nejednakost ostaje visoka u apsolutnim terminima, posebice u ukupnom broju dolaznih studenata. Van Der Wende (2015) ističe kako je europska mobilnost većinom intra-

europska, s preko 90% studentske mobilnosti, te upozorava kako se tradicionalni obrasci interkontinentalne mobilnosti s juga prema sjeveru i s istoka prema zapadu počinju odražavati i unutar Europe, gdje se povećavaju razlike između zemalja u pogledu ulaganja istraživanje i razvoj, te nestašici vještina, što je povezano s ekonomskom krizom. Kao posljedica toga, cirkulacija mozgova se vrlo lako može pretvoriti u odljev mozgova, a kulturna raznolikost se može smanjiti.

Tijekom svojih 30 godina Erasmus je doživio ogroman rast. Počevši samo s 11 članica EU-a, sudjelovanje se popelo na 33 zemlje, broj mobilnih studenata s 3 244 u prvoj godini (1987./1988.) nastavio je rasti. Očiti trend u Erasmusu je rast. Među većim zemljama, Španjolska ima najvišu stopu rasta. Iako je do Ujedinjenog Kraljevstva i Francuske bila tek treća po dolaznoj mobilnosti u 1998./1999., 2002./2003. je bila na samom vrhu s porastom većim od 60% a na tom vrhu je ostala i 2013./2014. akademske godine. To je značajno posebno u suprotnosti u odnosu na obrasce mobilnosti izvan programa, u kojoj Španjolska, kako Wächter i Wuttig ističu, uopće ne djeluje kao važna destinacijska zemlja (Wächter i Wuttig, 2011, 164).

Dvanaest zemalja centralne i istočne Europe koje su u programu počele sudjelovati 10 godina kasnije pokazuju najjače stope rasta, ali taj nalaz prekriva činjenicu da ukupni brojevi u većini slučajeva ostaju vrlo niski. U prvoj godini u kojoj su sve te zemlje sudjelovale, odlazna mobilnost iz tih zemalja bila je tek 8,2% od ukupne odlazne mobilnosti, i 1,7% dolazne. Također, sve zemlje, osim Malte, su „mrežni izvoznici“ (Wächter i Wuttig, 2011, 164/165). EU-16 zemlje i dalje šalju više studenata (u odnosu na vlastitu populaciju) nego grupa zemalja koja je u Erasmus program ušla 10 godina kasnije. Taj jaz može uzrokovati činjenica da EU- 16 zemlje su bogatije i mogu si priuštiti financijski trošak studiranja vani, no González, Mesanza, i Mariel (2011) ističu kako bi razlika mogla biti objašnjena samom prirodom Erasmus mobilnosti kao nečega što je vremenski zahtjevno u smislu vremena koje je potrebno kako bi se uspostavili potrebni kontakti s novim partnerima prije potpisivanja potrebnih sporazuma.

Španjolska, Francuska, Njemačka, Ujedinjeno Kraljevstvo i Italija po apsolutnim brojkama ističu se kao zemlje s najviše dolaznih i odlaznih studentskih mobilnosti, bilo u svrhu studija, ili stručne prakse. No ukoliko uzmemo u obzir udio koji odlazne mobilnosti čine u ukupnoj studentskoj populaciji, najveći pošiljatelji su Luksemburg, Lihtenštajn, Litva i Latvija. Velik udio odlaznih studenata možemo objasniti djelovanjem ograničenog kapaciteta zemalja pošiljateljica kao *push* faktora. Tremblay (2008) ukazuje kako je odlazna studentska mobilnost velika u manjim edukacijskim sistemima, koji nisu u

moгуćnosti pružiti cijeli niz terciarnih specijalizacija za koje bi njihovi studenti mogli biti zainteresirani.

Podaci o studentskoj mobilnosti u svrhu stručne prakse ukazuju na godišnji porast od 9% iako je i dalje zastupljenost tog tipa mobilnosti u odnosu na studentsku mobilnost u svrhu studijskog boravka višestruko manja (European Commission, 2015). Po pitanju mobilnosti osoblja, bilo u svrhu podučavanja, ili osposobljavanja, u akademskoj godini 2013./2014., najveće pošiljatelje čine Poljska, Turska, Španjolska, Njemačka i Rumunjska. Najveće primateljice mobilnosti osoblja u istoj akademskoj godini iste su kao i po pitanju studentske mobilnosti.

Trajanje razdoblja Erasmus studentskih mobilnosti u svrhu studija stabilno je tijekom vremena, a 2013./2014. iznosilo je 6,2 mjeseci. No taj prosjek sakriva činjenicu da oko polovine studenata boravi u inozemstvu jedan semestar, a druga polovica dva, tako da nam prosjek kaže malo o pojedinačnim slučajevima. Studentske mobilnosti u svrhu stručne prakse trajale su nešto kraće, 4,4 mjeseca. Trajanje mobilnosti osoblja u svrhu podučavanja, i u svrhu osposobljavanja ne razlikuju se mnogo, s prosjekom od 5,5 dana.

3.4. Topologija mreže mobilnosti

Mrežni pristup u istraživanju mobilnosti fokusira se ne samo na aktere koji u mreži sudjeluju već i na odnose među njima, njihovu ugrađenost u mrežu i međusobnu povezanost. Kao takav može pružiti uvid u stvaranje obrazaca koje možda drugačijim pristupom ne bi bilo moguće uočiti ili ne bismo obratili pažnju na njih. Većina dosadašnjih istraživanja (Jiang, 2014; Kondacki i dr., 2017.; Maggioni i Uberti, 2009, Shields, 2014) akademske mobilnosti koja koriste mrežnu analizu temelje se na dostupnim bazama podataka o studentskoj mobilnosti na razini zemalja. Ti podatci većinom pokrivaju mobilnost u svrhu stjecanja kvalifikacije, a analize uključuju mobilnosti studenata u cijelom svijetu. Istraživanje Breznik i suradnika (2013), te Breznik i Gologranc (2014) uključuje mrežnu analizu Erasmus mobilnosti u svrhu studijskog boravka, no s ponešto užim fokusom istraživanja. Rijetka istraživanja, poput istraživanja Derzsi i suradnika (2011), istražuju topologiju same mreže s ciljem boljeg uvida u dinamiku razvoja mreže, te istu uspoređuju s nekim postojećim modelima u svrhu stjecanja boljeg razumijevanja mrežnih modela kao takvih.

Većina većih društvenih mreža prikazuje značajke društvene složenosti koja uključuje bitne netrivialne značajke mrežne topologije, s uzorcima složenih veza između elemenata koji nisu ni potpuno učestali niti čisto slučajni. Proučavanje brojnih velikih mreža koje postoje u svijetu ukazalo je na učestalu prisutnost koncentratora, odnosno čvorova u mreži s jako velikim brojem veza, tj. jako velikim stupnjem. Stupanj čvora (eng. *degree*) označava broj direktnih veza koje taj čvor ima. Kod usmjerenih mreža veze između čvorova označavaju se strelicama, stoga možemo razlikovati ulazni ili izlazni stupanj. Ulazni stupanj (eng. *indegree*) označava broj strelica koje čvor prima, dok izlazni stupanj (eng. *outdegree*) označava broj strelica koje čvor šalje. Barabási i Albert (1999) pokazali su kako distribucija stupnja u nesrazmjernim mrežama prati distribuciju zakona potencije, što rezultira time da većina čvorova u mreži ima jednako malen broj veza, dok nekoliko koncentratora ima nesrazmjerno velik broj veza. Derzsi i dr. (2011) navode brojne primjere i rezultate istraživanja koji ukazuju na nesrazmjerna svojstva raznih velikih mreža koje možemo naći u stvarnom svijetu.

Barabási i Albert (1999) elaborirali su model nesrazmjerne mreže kroz dva „sastojka“: neprestan rast i preferencijalno povezivanje. To znači da mreža nije statična, već joj se konstantno priključuju novi akteri, koji onda imaju veću tendenciju povezivanja s akterima koji već imaju mnogo veza. Samim time čvorovi koji imaju više veza brže stječu nove. Možemo reći da dolazi do svojevrstne akumulacije prednosti, odnosno da mreža raste po principu „bogatiji postaju bogatiji“. U našem slučaju to znači da visoka učilišta (i poduzeća) ulaskom u program teže sklapanju partnerstava s institucijama koje su već dobro umrežene, odnosno povezane.

Ispitujući mrežu mobilnosti Erasmus studenata u svrhu studijskog boravka, u akademskoj godini 2002./2003. Derzsi i suradnici (2011) pokazuju kako je distribucija stupnja zapravo eksponencijalna. Autori uzrok takvom nalazu vide u eksponencijalnoj prirodi distribucije veličine visokih učilišta. Njihova pretpostavka da je broj veza koje visoko učilište ima proporcionalan njegovoj veličini, temelji se na pretpostavci da je broj veza visokih učilišta proporcionalan broju profesionalnih veza profesora, što je pak "neizbježno" proporcionalno broju profesora. A broj profesora po autorima pak odražava ukupan broj studenata visokog učilišta. S obzirom da je jedan od dva „sastojka“ nesrazmjerne mreže rast, zanima nas hoće li distribucija biti drugačija na našoj mreži, s obzirom da uključuje dva tipa mobilnosti, duže vremensko razdoblje koje je uz to više od deset godina kasnije.

4. Hipoteze

Pregledom relevantne literature vezane za temu ovog rada, formirale su se određene pretpostavke o fenomenu koji istražujemo, te o rezultatima do kojih bismo ovim istraživanjem mogli doći. Vodeći se ciljevima istraživanja, a na temelju navedenih pretpostavki utemeljenih na prethodno prezentiranoj literaturi, formulirali smo hipoteze kako slijedi:

H1 – Mreža Erasmus+ mobilnosti na razini institucija odražava istaknuto svojstvo nesrazmjernih mreža, odnosno distribucija stupnja prati distribuciju funkcije potencije.

H2 – Struktura mreže sveukupne Erasmus+ mobilnosti na razini zemalja odražava strukturu jezgra/periferija.

H3 – Strukturni prestiž visokih učilišta u mreži Erasmus+ mobilnosti ne odgovara društvenom prestižu koji visoka učilišta uživaju u društvu.

H4 – Akademsko osoblje značajno je sklonije odlasku na mobilnost na prestižnija visoka učilišta od studenata.

5. Metodologija

U istraživanju se koristimo podacima o dolaznim i odlaznim mobilnostima visokih učilišta u okviru programa ERASMUS +, koje nam je ustupila Agencija za mobilnost i programe Europske unije. Vremensko razdoblje na koje se podatci odnose obuhvaća 2014., 2015. i 2016. natječajnu godinu. Uz samu informaciju o natječajnoj godini, zemlji i instituciji primateljici i pošiljateljici, baza podataka sadrži i informaciju o vrsti mobilnosti. U okviru Erasmus+ programa možemo razlikovati 4 tipa mobilnosti:

1. studentska mobilnosti u svrhu studijskog boravka (*student mobility for studies* – SMS)
2. studentska mobilnost u svrhu stručne prakse (*student mobility for placements* – SMP)
3. mobilnost osoblja u svrhu podučavanja (*staff mobility for teaching assignments* – STA)
4. mobilnost osoblja u svrhu osposobljavanja (*staff mobility for training* – STT)

Za SMS i STA tip mobilnosti u mogućnosti smo konstruirati mrežu, no zbog velike količine podataka i nemogućnost usustavljenja naziva poduzeća koja sudjeluju u programu, SMP i STT tip mobilnosti analiziramo isključivo na razini zemalja sudionica. Također, u obzir smo uzeli samo ostvarene mobilnosti.

Bazu podataka nadopunili smo rangom visokih učilišta, služeći se Times Higher Education rang-ljestvicom visokih učilišta u Europi u 2017. godini. Prema Marginson i van der Wende (2009) 40% indeksa koji Times Higher Education ljestvica koristi pri izračunu ranga sastoji se od međunarodne ankete akademika, 10% od ankete "globalnih poslodavaca". Nadalje, postoje dva indikatora internacionalizacije: udio međunarodnih studenata (5%) i udio međunarodnih zaposlenika (5%). 20% određuje omjer studenata i osoblja, što za mnoge rang-ljestvice predstavlja indikator kvalitete nastave. Preostalih 20% se sastoji od performansi po pitanju istraživačke citiranosti. Za visoka učilišta koja su se našla na popisu navedene rang-ljestvice upisali smo i dostupne podatke o visokim učilištima:

- broj upisanih studenata;
- omjer studenata i profesora;
- broj međunarodnih studenata.

Za samu mrežnu analizu korišten je Pajek, program za vizualizaciju i analizu velikih mreža, dok je za testiranje distribucije broja partnera visokih učilišta, odnosno hipoteze o preferencijalnom povezivanju, koje karakterizira distribucija koja odgovara distribuciji funkcije potencije, korišten EasyFit, softver za testiranje distribucija.

6. Rezultati i rasprava

Glavni cilj analize društvenih mreža je detekcija i interpretacija obrazaca društvenih veza između aktera (De Nooy, Mrvar i Batagelj, 2011). Sama mreža je dakle određena setom aktera i setom veza između njih. U mreži Erasmus mobilnosti na razini institucija, najmanju jedinicu, dakle aktere, predstavljaju visoka učilišta i poduzeća koja sudjeluju u programu, dok veze između njih čine mobilnosti ostvarene u promatranom razdoblju. S obzirom da su mobilnosti usmjerene s matične institucije na prihvatnu instituciju, radi se o usmjerenoj mreži, a broj mobilnosti označava jačinu veze. Kako bi

partnerstvo između dva visoka učilišta smatrali realiziranim potrebno je da se ostvari minimalno jedna mobilnost, u bilo kojem smjeru.

6.1. Osnovne karakteristike mreže

Mreža SMS i STA mobilnosti sadrži ukupno 3987 institucija, a zbog toliko velikog broj čvorova i veza grafička reprezentacija cjelokupne mreže nije informativna, odnosno nije pogodna za vizualnu inspekciju. Za mrežu kažemo da je povezana ukoliko između svaka dva čvora postoji put. Povezana komponenta grafa je najveći podskup čvorova u kojem između svaka dva čvora postoji put. Mreža SMS i STA mobilnosti sadrži 30 povezanih komponenti, među kojima se ističe najveća komponenta (eng. *giant component*) koja sadrži 3807 (97,7 %) čvorova. Prosječna najkraća udaljenost između čvorova na povezanim dijelovima grafa neusmjerene verzije mreže iznosi 2,99, s najduljom udaljenosti od 9 koraka. Čvorove, odnosno institucije, povezuje 121 158 usmjerenih veza, od kojih je 37 335 (30,82%) jako slabo i ima vrijednost jedan. To znači da se između dvije institucije ostvarila tek jedna razmjena. Da bi partnerstvo dviju institucija označili kao uzajamno, potrebno je da se ostvari barem jedna mobilnost u svakom smjeru. Reciprocitet je mjera vjerojatnosti da su čvorovi u usmjerenoj mreži međusobno povezani, a računa se kao omjer veza koje su dio uzajamnog odnosa u odnosu na ukupan broj ostvarenih veza. U našoj mreži reciprocitet iznosi 0,58. Hanneman i Riddle (2005) ističu kako su mreže u kojima prevladavaju uzajamne, simetrične veze često više stabilne ili „jednake“ u odnosu na one u kojima prevladavaju asimetrične veze, što karakterizira hijerarhije. Pri računanju stupnja čvorova, odnosno broja različitih partnera koje institucije imaju, zanemarili smo smjer veze. Partnerstvo se smatra sklopljenim, iako nije uzajamno, ukoliko se ostvarila barem jedna mobilnost. Prosječan broj partnera u mreži je 44 ($s=76,51$, medijan=11). U dosadašnjem radu već smo opisali jedan mehanizam povezivanja institucija u mreži, onaj preferencijalnog povezivanja. No, povezivanje aktera u mreži može biti i rezultat homofilije, odnosno tendencije aktera da se poveže s drugim akterima sličnog tipa. Tako dvoje ljudi koji imaju zajedničkog prijatelja imaju tendenciju da se kroz neko vrijeme upoznaju. U našoj mreži to znači da dvije institucije koje imaju zajedničkog partnera imaju tendenciju međusobno sklopiti partnerstvo. S obzirom da nam je samo bitno je li partnerstvo ostvareno kroz barem jednu mobilnost, nije nam bitan smjer veze. U mrežnoj analizi taj fenomen mjerimo koeficijentom grupiranja (eng. *clustering coefficient*), a možemo razlikovati globalni i

lokalni koeficijent. Globalni koeficijent nam daje cjelokupnu naznaku grupiranja u mreži, dok nam lokalnu daje indikator ugrađenosti pojedinih čvorova u mreži. Globalni koeficijent grupiranja, često nazivan i tranzitivnost, računa se kao omjer zatvorenih trijada i ukupnog broja trijada (Wasserman i Faust, 1994, 243). Za našu mrežu SMS i STA mobilnosti on iznosi 0,164. Alternativu ovom koeficijentu predstavlja Watts-Strogatz koeficijent grupiranja koji predstavlja zapravo prosjek lokalnog koeficijenta grupiranja svih čvorova u mreži. U našem slučaju to je 0,167, stoga možemo reći da je razlika zanemariva. Malena razina tranzitivnosti vraća nas sa homofilije na pitanje preferencijalnog povezivanja i našu prvu hipotezu.

Koristeći EasyFit softver za testiranje distribucija, a vodeći se rezultatima Kolmogorov-Smirnov testa, dolazimo do rezultata da se distribucija stupnja naše mreže značajno razlikuje od svih 60 ponuđenih distribucija, uključujući i distribuciju funkcije potencije, Paretovu distribuciju i eksponencijalnu distribuciju. To znači da moramo odbaciti hipotezu o nesrazmjernoj prirodi naše mreže. Ovakav rezultat odstupa i od naših predviđanja postavljenih na temelju prethodnih istraživanja o prisutnosti nesrazmjernih mreža u stvarnom svijetu, ali i od rezultata koje su dobili Derzsi i suradnici (2011). S obzirom da smo prikupljajući podatke o rangui visokih učilišta prikupili i podatke o broju upisanih studenata, te omjeru studenata spram profesora, valjalo bi napomenuti kako pri testiranju povezanosti nismo dobili značajnu korelaciju između njih ($r=,103$, $p>0,05$). Derzsi i suradnici (2001) svoju tezu o eksponencijalnoj distribuciji broja partnera kao rezultatu eksponencijalne prirode distribucije veličine visokih učilišta temelje upravo na pretpostavci da je broj profesora proporcionalan broju studenata (te da su partnerske veze visokog učilišta utemeljene na profesionalnim vezama profesora). Nadalje, distribucija veličine visokih učilišta, također značajno odstupa od eksponencijalne distribucije. Ovakvo odstupanje može biti rezultat specifičnog uzorka. Naime, Derzsi i suradnici (2001) svoju hipotezu o eksponencijalnoj distribuciji veličine visokih učilišta testirali su na slučajnom uzorku od 180 visokih učilišta, dok su naši rezultati dobiveni na rezultatima visokih učilišta koja se nalaze na Times Higher Education rang-ljestvici.


Razlog odstupanja distribucije stupnja od očekivanja može se kriti upravo u aspektu rasta nesrazmjerne mreže. Naime, s obzirom da je broj visokih učilišta koja mogu sudjelovati u programu ograničen, sama mreža je ograničena u svom rastu. To znači da visoka učilišta koja su već dobro povezana ne mogu stjecati velik broj novih partnera velikom brzinom. To pak daje vremena manje povezanim visokim učilištima da se bolje povežu i smanje razliku u broju partnera. Kako bismo ispitali ovu pretpostavku nužno je

sagledati distribuciju stupnja u mreži Erasmus mobilnosti kroz vrijeme, što u ovom istraživanju nije moguće.

Globalnu perspektivu možemo sagledati ukoliko sva visoka učilišta neke zemlje, zajedno sa vezama „skupimo“ u jedan novi čvor. No, s obzirom da informaciju o zemlji pošiljateljici i primateljici imamo i za druga dva tipa mobilnosti, najbolji uvid dobit ćemo koristeći potpuno novu mrežu. U mreži mobilnosti na razini zemalja, svaka zemlja predstavlja čvor a broj ostvarenih mobilnosti između zemalja predstavlja snagu veze. Sada imamo značajno manju (33 čvora) i gušću mrežu. Gustoća (engl. *density*) mreže mjera je gustoće veza, a računa se kao omjer ostvarenih i svih mogućih veza. Možemo reći da gustoća mjeri razinu povezanosti te služi kao općenita mjera kohezije. No, ta mjera ima više smisla za malene grupe u kojima je suradnja između aktera učestalija, stoga smo ju nismo prije računali. Gustoća mreže mobilnosti na razini zemalja je 0,95, što je očekivano s obzirom da se mobilnosti ne ostvaruju tek između nekoliko rijetkih parova zemalja. Više o samoj teksturi mreže možemo saznati iz njezinih osnovnih dijelova. Dijada je par čvorova i veza između njih. U usmjerenjnoj mreži možemo razlikovati:

- praznu dijadu (eng. *null dyad*), koja označava nepostojanje veze između dva čvora,
- potpunu dijadu (eng. *complete dyad*), koja označava povezanost čvorova uzajamnim odabirom,
- te asimetričnu dijadu (eng. *asymmetric dyad*), koja označava nesimetričnu povezanost dva čvora u kojoj postoji usmjerena veza iz jednog čvora ka drugom, no nije uzvraćena.

No, kako bismo obuhvatili strukturu usmjerene mreže, pozornost moramo obratiti na trijade. Na Slici 1. možemo vidjeti 16 tipova trijada koje se mogu pojaviti u usmjerenjnoj mreži. Tip trijade označen je troznamenkastim brojem i ponekad slovom. Prvi broj označava broj potpunih dijada, drugi broj označava broj asimetričnih dijada, a treći pak broj praznih dijada. Slova označavaju smjerove strelica, odnosno usmjerenih veza (U=gore, C=ciklične, T=tranzitivne). Pokazano je kako se cjelokupna struktura usmjerenih mreža može zaključiti na temelju tipova trijada koji se u njoj pojavljuju.



Slika 1. Tipovi trijada u Pajeku. Preuzeto iz De Nooy, Mrvar i Batagelj, 2011, 207

De Nooy, Mrvar i Batagelj (2011) opisuju pet teorijskih modela uravnoteženosti mreže, temeljenih na učestalosti određenih tipova trijada, pri čemu je svaki sljedeći manje restriktivan, odnosno dopušta pojavu trijada koje se javljaju u prethodno navedenom modelu.

Model uravnoteženosti – dopušta tek dva tipa trijada, 300 i 102. Svaki klaster je klika, odnosno maksimalna potpuna submreža¹ koja sadrži tri ili više čvorova. Karakteristike modela su simetrične veze unutar klastera, nepostojanje veza između klastera, te postojanje maksimalno dva klastera.

Model klasterabilnosti – ovaj model nema restrikciju na broj klastera, odnosno dopušta postojanje više klika koje nisu međusobno povezane, stoga se i trijada tipa 003 može pojaviti u ovom modelu.

Model rangiranih klastera – mreža se sastoji od klika i rangova, na način da klike unutar ranga nisu povezane, a klike između rangova povezane su asimetričnim dijadama

¹ Potpuna mreža je mreža s maksimalnom gustoćom, sve moguće povezanosti se ostvaruju.

koje su usmjerene prema višem rangu. Model uz pojavu prethodno navedenih tipova trijada dopušta i pojavu 021D, 021U, 030T, 120D i 120U.

Model tranzitivnosti – sastoji se od klika i rangova, na način da klike unutar ranga nisu povezane a klike između rangova povezane su praznim ili asimetričnim dijadama usmjerenim prema višem rangu. Model dopušta pojavu i 012 tipa trijadi.

Model hijerarhijskih klastera - ovaj model uključuje sve uvjete prethodnog modela, uz dodatak da klasteri ne smiju sadržavati krug asimetričnih dijada. Model omogućuje i pojavu 120C i 210 tipa trijade.

021C, 111D, 111U, 030C i 201 su „zabranjeni“ tipovi trijada, odnosno njihova prisutnost označava da na mrežu nije primjenjiv niti jedan od navedenih modela jer su kontradiktorne svim pretpostavkama o simetričnosti i asimetričnosti dijada na kojima se temelje navedeni modeli.

Tablica 1. Trijadni popis mreže ukupnih mobilnosti na razini zemalja

Tip trijade	Broj trijada u mreži (ni)	Očekivani broj trijada (ei)	Relativna razlika (ni-ei)/ei	Model
3 - 102	22	0,08	271,77	Uravnoteženost
16 - 300	4453	4054,03	0,1	Uravnoteženost
1 - 003	1	0	14443,02	Klasterabilnost
4 - 021D	3	0,08	36,2	Rangirani klasteri
5 - 021U	0	0,08	-1	Rangirani klasteri
9 - 030T	3	3,18	-0,06	Rangirani klasteri
12 - 120D	40	31,32	0,28	Rangirani klasteri
13 - 120U	24	31,32	-0,23	Rangirani klasteri
2 - 012	8	0,01	976,31	Tranzitivnost
14 - 120C	44	62,64	-0,3	Hijerarhijski klasteri
15 - 210	583	1234,36	-0,53	Hijerarhijski klasteri
6 - 021C	1	0,16	5,2	Zabranjeni
7 - 111D	31	3,18	8,75	Zabranjeni
8 - 111U	44	3,18	12,84	Zabranjeni
10 - 030C	0	1,06	-1	Zabranjeni
11 - 201	199	31,32	5,35	Zabranjeni


Kao što De Nooy, Mrvar i Batagelj (2011) ističu, društvene mreže se ipak gotovo nikad ne uklapaju savršeno u neki od modela. Vjerojatno je da će se svaki tip trijade

pojaviti barem jednom, stoga prisutnost jedne trijade nekog tipa ne znači nužno da se povezani model treba primijeniti. Iz tog razloga, potrebno je dobivenu distribuciju tipova trijada usporediti s onom koju možemo očekivati u nasumičnoj mreži s istim brojem čvorova i veza. Ukoliko je pak učestalost određenog tipa trijade u mreži malo veća od očekivane, povezani model se ne primjenjuje, te se mreža smatra nasumičnom. U Tablici 1. nalazi se trijadni popis za mrežu ukupnih Erasmus+ mobilnosti na razini zemalja. Kao što možemo vidjeti broj „zabranjenih“ tipova trijada značajno je zastupljeniji u mreži no što je očekivano, stoga na samu mrežu nije primjenjiv ni jedan od modela.

6.2. Analiza na razini zemalja

Na Slici 2. možemo vidjeti matrični prikaz mreže ukupne mobilnosti u Erasmus+ programu. Radi se o apsolutnim vrijednostima, pri čemu tamnija nijansa predstavlja viši broj ostvarenih mobilnosti. S obzirom da se radi o usmjereoju mreži, matrica nije simetrična. Pri tom redovi u matrici predstavljaju pošiljatelje, a stupci primatelje. S obzirom da je Erasmus programom onemogućeno da se ostvari razmjena između dva visoka učilišta iste zemlje, dijagonala matrice je prazna. Zbog velikog raspona u vrijednostima, ćelije koje označavaju malen broj ostvarenih mobilnosti teško je vizualno razlikovati, kako međusobno, tako i od ćelija na dijagonali, koje označavaju nepostojanje ostvarenih mobilnosti. No, ono što možemo primijetiti jest koncentracija ćelija koje označavaju visoke apsolutne vrijednosti oko pet zemalja: Njemačke, Francuske, Španjolske, Ujedinjenog Kraljevstva i Italije, odnosno oko veza koje imaju među sobom. Ovakva struktura odražava karakteristike strukture jezgra-periferija, pri čemu se najsnažnije veze koncentriraju u jezgri, nešto slabije veze između jezgre i semiperiferije, a najslabije veze u periferiji i između periferije i semiperiferije. To rezultira koncentracijom veza na horizontalnoj i vertikalnoj traci povezanoj s jezgrom, i potvrđuje našu drugu hipotezu.

Pošiljatelji




Primatelji DE FR ES UK IT HR TR BE DK LV PT FI SK BG EE LT EL RO PL CY SI CZ NL HU IE AT SE IS LU MT NO LI MK

Slika 2. Matrični prikaz ukupne mobilnosti


U mrežnoj analizi pozicija aktera izjednačena je sa specifičnim obrascem veza. Pri tom se za aktere sa sličnim obrascem veza kaže da su „relacijski ekvivalentni, da tvore ekvivalentnu klasu, ili da zauzimaju ekvivalentnu poziciju u mreži“ (De Nooy, Mrvar i Batagelj, 2011, 265). Dva čvora strukturalno su ekvivalentna ukoliko imaju identične veze sami sa sobom, među sobom i sa svim drugim čvorovima. To implicira da zamjena njihovih mjesta ne bi imala nikakve posljedice na strukturu mreže. Veza čvora sa samim sobom zove se petlja (eng. *loop*). S obzirom da je, kao što smo već napomenuli, Erasmus programom onemogućeno da se ostvari razmjena između dva visoka učilišta iste zemlje, u našoj mreži ne postoje petlje, stoga se pri računanju strukturne ekvivalencije vodimo samo vezama čvorova među sobom i sa svim drugim čvorovima. Grupiranje zemalja sa sličnom strukturalnom pozicijom u mreži u Pajeku je postignuto hijerarhijskom klaster analizom, točnije Ward metodom. Za izračun različitosti čvorova, na kojoj metoda počiva, korištena je Euklidska distanca. Na dendogramu, prikazanom na Slici 3. jasna je

podjela između klastera u koji spadaju Njemačka, Francuska, Španjolska, Ujedinjeno Kraljevstvo i Italija, s ostatkom mreže.



Slika 3. Dendrogram

Matrica različitosti na Slici 4. detaljnije prikazuje strukturalnu distancu između zemalja. Tamnija boja ćelije ukazuje na veću strukturalnu razliku. S obzirom da je ova matrica simetrična, dijagonala ima razliku 0.



LT EL HU RO SK CZ DK NO AT FI SE IE BE NL PT TR PL LV EE MT HR SI BG IS LU LI MK CY DE FR UK ES IT

Slika 4. Matrica razlika

Jezgra koju predstavlja navedenih pet zemalja, značajno se razlikuje od ostalih zemalja. Među ostalim zemljama možemo napraviti još jednu podjelu na dva klastera koja odgovaraju našoj strukturi periferije i semiperiferije. Pri tom primjećujemo kako klaster periferije čine međusobno najslbličnije zemlje. Ono što je također zanimljivo primijetiti jest da strukturalna sličnost grupacija zemalja koje su u program uključile u sličnom razdoblju. Na samoj periferiji nalaze se strukturalno najslbličnije ali i najmanje zemlje koje ne čine velik udio u ukupnoj mobilnosti programa, uključujući i Hrvatsku.

U usmjerenim mrežama obično možemo identificirati dva tipa važnih čvorova: žarišta (eng. *hubs*) i autoritete (eng. *authorities*). Prema Kleinbergu (1998) čvor je dobro žarište ukoliko ukazuje na mnogo autoriteta, a dobar autoritet ukoliko na njega ukazuju brojna žarišta. S obzirom na cirkularnost definicije, pojmove je najbolje pojasniti primjerom. Mrežu možemo zamisliti kao nogometno tržište pri čemu zemlje povezuje

uvoz i izvoz igrača. Pri tom neke zemlje imaju podjednak uvoz i izvoz, a neke zemlje su isključivo izvoznici ili uvoznici. U ovom primjeru, zemlje koje imaju dobre nogometne lige predstavljaju autoritete, a zemlje koje imaju dobre igrače dobra žarišta. Koliko igrača zemlja izvozi (*weighted outdegree*) i u koliko različitih zemalja (*outdegree*) je bitno, no veća težina je na tome da li su zemlje u koje se izvozi zemlje s dobrim ligama, odnosno zemlje u koje mnogi drugi izvoze svoje igrače, tj. autoriteti. Time ova mjera zapravo mjeri koliko je netko „dobar“ izvoznik. Istom logikom, da bi zemlja bila dobar autoritet mora uvoziti ne samo velik broj igrača iz velikog broja zemalja, već iz zemalja koje su žarišta. Dakle, možemo reći da centralitet autoriteta mjeri koliko je čvor „dobar“ uvoznik. U Erasmus mreži igrače zamjenjuju studenti i akademsko osoblje. Kao što u Tablici 2. možemo primijetiti zemlje jezgre nalaze se na samom vrhu i po pitanju autoriteta i po pitanju žarišta, što ih čini i „dobrim“ uvoznicima i izvoznicima. Visoka učilišta iz prvih pet zemalja čini 61,64% najboljih u Europi, po ljestvici Times Higher Educationa za 2017. godinu. Švedska i Irska spadaju pod „dobre“ uvoznike, a Poljska, Rumunjska i Turska ističu se kao „dobra“ žarišta. Zemlje periferije nalaze se na samom dnu tablice.

Tablica 2. Centraliteti autoriteta i žarišta po zemljama

ZEMLJA	Mjera autoriteta	Mjera žarišta	ZEMLJA	Mjera autoriteta	Mjera žarišta
ES	0,575	0,374	DK	0,0647	0,0498
UK	0,4275	0,2185	RO	0,0429	0,0875
DE	0,3421	0,4568	EL	0,0413	0,0591
FR	0,3413	0,4869	LT	0,0323	0,0481
IT	0,2808	0,4455	SK	0,0298	0,0366
PL	0,1601	0,2268	MT	0,0271	0,0043
PT	0,1492	0,1057	SI	0,0234	0,0226
BE	0,1378	0,1125	LV	0,0198	0,0214
NL	0,1343	0,1528	EE	0,0192	0,0139
SE	0,1301	0,0547	HR	0,0187	0,0192
FI	0,1101	0,0788	BG	0,0157	0,0299
IE	0,1095	0,0429	LU	0,0108	0,007
TR	0,1008	0,1339	IS	0,01	0,0046
CZ	0,0949	0,0954	CY	0,0095	0,0058
AT	0,0786	0,0893	MK	0,0009	0,001
NO	0,0773	0,0285	LI	0,0006	0,0006
HU	0,0662	0,0536			

Akadske razmjene obično se vode načelom reciprociteta, pa tako i Erasmus program. Načelo reciprociteta označava težnju za uravnoteženosti između priljeva i odljeva studenata i akademskog osoblja. Ipak, koncept uravnotežene mobilnosti nema zajednički dogovorenu definiciju od strane zemalja uključenih u program. U svrhu ovog rada, preuzeli smo definiciju uravnoteženosti od Ferenz (2011) koja navodi kako je „uravnotežen slučaj onaj u kojem je razlika u IN:OUT omjeru između broja dolaznih i odlaznih studenata manja od 10“ (Ferenz, 2011, 89).

Tablica 3. Omjer ukupne dolazne i odlazne mobilnosti po zemljama

Zemlja	IN:OUT omjer ukupne dolazne i odlazne mobilnosti	
MT	633:100	Zemlje uvoznice
NO	243:100	
IE	228:100	
SE	219:100	
IS	200:100	
UK	186:100	
CY	173:100	
PT	150:100	
LU	139:100	
DK	136:100	
FI	125:100	
EE	122:100	
HU	119:100	
ES	119:100	
BE	116:100	
SI	109:100	Uravnotežene zemlje
LI	103:100	
CZ	102:100	
AT	100:100	
HR	99:100	
NL	94:100	
MK	87:100	Zemlje izvoznice
EL	86:100	
DE	84:100	
IT	77:100	
LV	76:100	
FR	74:100	
SK	72:100	
PL	71:100	
LT	62:100	
TR	58:100	
BG	50:100	
RO	43:100	

Nasuprot tome, zemlje s neravnotežom između priljeva i odljeva možemo klasificirati ili kao zemlje uvoznice (omjer jednak ili veći od 110:100) ili kao zemlje izvoznice (omjer jednak ili manji od 90:100). U Tablici 3. možemo vidjeti IN:OUT omjere ukupne dolazne i odlazne mobilnosti za sve zemlje koje sudjeluju u Erasmus programu. Promatrajući rezultate možemo primijetiti kako, unatoč idealu o uravnoteženosti kojim se vodi Erasmus program, tek šest zemalja, uključujući i Hrvatsku, ima ujednačene tokove dolaznih i odlaznih mobilnosti. Od preostalih 27 zemalja, 15 su mrežne uvoznice, a 12 mrežne izvoznice. Također možemo primijetiti kako su srednjoistočne i jugoistočne zemlje većinom izvoznice, dok su zapadne zemlje većinom uvoznice. Najveću iznimku pritom čine Malta (koja ujedno ima i najekstremniji omjer) i Cipar. Neuravnoteženost omjera u zemljama izvoznicama i uvoznicama ima širok raspon. Pri tom Rumunjska i Bugarska na mobilnost šalju više no dvostruko više studenata i akademskog osoblja nego što im na mobilnost dolazi. Malta ima najmanje uravnotežen omjer priljeva i odljeva, pri čemu je priljev više no šest puta veći od odljeva. S manje ekstremnom neuravnoteženošću, no i dalje više no duplo većom dolaznom mobilnosti, prate ju Norveška, Irska, Švedska i Island. Omjer centraliteta žarišta i autoriteta daje nam istu podjelu zemalja na uvoznice i izvoznice, no valja primijetiti kako, primjerice Malta, s višestruko većim uvozom, ima jako nizak centralitet autoriteta, što ju ne čini „dobrim“ uvoznikom. S druge strane pak, Španjolska ima najviši centralitet autoriteta, što ju čini „najboljim“ uvoznikom, a omjer uvoza i izvoza joj je tek blaže neuravnotežen. Isto vrijedi i za Njemačku, Francusku i Italiju, koje su po centralitetu žarišta „najbolji“ izvoznici, dok se po omjeru izvoza i uvoza ne mogu mjeriti sa Rumunjskom, koja pak, unatoč više no duplo većem izvozu, ima jako nizak centralitet žarišta, odnosno nije „dobar“ izvoznik.

Detaljan prikaz tokova dolazne i odlazne mobilnosti u Hrvatskoj možemo vidjeti u Tablici 4. Najveći priljev studenata i akademskog osoblja dolazi iz istočnih zemalja. Po apsolutnom broju dolaznih mobilnosti ističe se Poljska, a slijede ju Španjolska, Slovenija, Njemačka, Francuska, Italija, Češka i Portugal. Po pitanju odlaznih mobilnosti najpopularnije odredište je Njemačka, zatim Španjolska, Austrija, Italija, Poljska, Češka, te Francuska.

Tablica 4. Prikaz hrvatskih odlaznih i dolaznih mobilnosti po zemljama

Zemlja	IN:OUT omjer	Broj dolaznih mobilnosti	Broj odlaznih mobilnosti
LT	424:100	191	45
RO	381:100	118	31
TR	265:100	159	60
BG	253:100	96	38
MK	238:100	50	21
PL	221:100	879	397
LV	203:100	81	40
SK	193:100	145	75
FI	168:100	101	60
EL	150:100	54	36
FR	145:100	313	216
SI	97:100	356	366
HU	95:100	118	124
ES	85:100	376	440
EE	84:100	31	37
CZ	82:100	223	272
BE	80:100	84	105
IT	64:100	262	412
PT	62:100	217	349
NL	60:100	44	73
DE	58:100	333	577
IE	50:100	16	32
NO	50:100	14	28
UK	49:100	64	131
CY	38:100	5	13
AT	38:100	164	435
SE	33:100	26	79
DK	19:100	5	26
MT	14:100	4	28
IS	0:100	0	6
LU	0:100	0	2
LI	0:100	0	1

Ono što nas nadalje zanima jest omjer dolaznih i odlaznih mobilnosti po različitim tipovima mobilnosti. Rezultati su prikazani u Tablici 5., a kao što možemo vidjeti niti jedna zemlja nema uravnotežen priljev i odljev mobilnosti u svim kategorijama. Mađarska, Belgija i Austrija najbliže su tome idealu. S druge strane Bugarska, Latvija i Rumunjska mrežni su izvoznici u svim kategorijama, Malta, Island, Irska i Cipar mrežni uvoznici. U 2008./2009. akademskoj godini tek su tri zemlje (Austrija, Belgija, Estonija) imale uravnotežene tokove studentskih mobilnosti u svrhu studijskog boravka. U našem

slučaju ih je devet, no pritom je Estonija promijenila profil, te prima mnogo više studenata u svrhu studijskog boravka, no što ih šalje na razmjenu.

Tablica 5. Omjeri dolaznih i odlaznih studenata po kategorijama mobilnosti

ID	SMS	SMP	STA	STT
AT	103:100	91:100	89:100	122:100
BE	101:100	174:100	91:100	102:100
BG	55:100	38:100	73:100	31:100
CY	170:100	125:100	358:100	231:100
CZ	105:100	104:100	86:100	114:100
DE	73:100	127:100	89:100	101:100
DK	156:100	94:100	109:100	168:100
EE	192:100	71:100	119:100	55:100
EL	61:100	124:100	132:100	84:100
ES	107:100	166:100	114:100	127:100
FI	154:100	67:100	115:100	86:100
FR	81:100	50:100	112:100	118:100
HR	104:100	74:100	179:100	68:100
HU	144:100	90:100	95:100	102:100
IE	217:100	255:100	127:100	432:100
IS	194:100	373:100	144:100	154:100
IT	69:100	65:100	168:100	209:100
LI	97:100	369:100	109:100	32:100
LT	85:100	23:100	83:100	52:100
LU	24:100	749:100	270:100	131:100
LV	96:100	39:100	157:100	43:100
MK	18:100	224:100	168:100	538:100
MT	161:100	1658:100	220:100	949:100
NL	97:100	79:100	96:100	178:100
NO	278:100	481:100	121:100	87:100
PL	106:100	32:100	54:100	33:100
PT	160:100	94:100	170:100	246:100
RO	51:100	24:100	64:100	30:100
SE	243:100	268:100	90:100	117:100
SI	131:100	70:100	102:100	86:100
SK	53:100	38:100	144:100	110:100
TR	56:100	53:100	91:100	52:100
UK	186:100	204:100	81:100	245:100

Uspoređujući IN:OUT omjere SMS mobilnosti zemalja koje sudjeluju u Erasmus programu s podacima o mobilnosti u svrhu stjecanja kvalifikacije, Ferenz (2011) naglašava kako je razlika između dolaznih i odlaznih tokova studenata puno veća kada je u pitanju mobilnost u svrhu stjecanja kvalifikacije, nego Erasmus mobilnost. To pak,

uz činjenicu da u odnosu na 2008./2009. akademsku godinu trostruko više zemalja ima ujednačene tokove studenata u svrhu studijskog boravka, upućuje na zaključak da je program, vodeći se idealom reciprociteta, relativno uspješan u kontroliranju razlike između odljeva i priljeva studenata. Vremenski odmak mogao bi objasniti i zašto su tokovi u SMP i STT tipu mobilnosti, koji su u program uvedeni tek 2007. godine, manje uravnoteženi.

6.3. Analiza na razini institucija

Od početka Erasmus + programa, odnosno od natječajne godine 2014. do 2016., u programu je sudjelovalo ukupno 3987 institucija, u studentskim mobilnostima u svrhu studijskog boravka, te mobilnostima osoblja u svrhu podučavanja. Već smo napomenuli da je prosječan broj partnera koji institucije u mreži imaju 44 ($s=76,51$, medijan=11), no čak nam ni distribucija broja partnera ne kaže jesu li institucije s velikim brojem veza grupirane ili su raširene po cijeloj mreži. Jedan od načina za detekciju kohezivnih subgrupa u mreži je k -jezgra (eng. *k-core*), što označava maksimalnu submrežu u kojoj svaki čvor ima stupanj minimalne vrijednosti k unutar submreže. Razgradnja mreže na k -jezgre dobro je utvrđena mjera koja dijeli mrežu od vanjskih ka više centralnim čvorovima. U velikim mrežama, izbacivanje grupa s najmanjim k vrijednostima rezultira razbijanjem mreže na relativno gusto povezane komponente. U našoj mreži, jezgra s najvišom vrijednosti sadrži 234 čvora, a najmanji stupanj unutar nje je 131 što je čini najpovezanijom komponentom mreže. U Tablici 6. možemo vidjeti zastupljenost visokih učilišta u jezgri po zemljama. Visoka učilišta iz pet zemalja jezgre, zastupljena su u ovoj k -jezgri sa 61,53%. Slijede ih zapadne zemlje, Poljska, Češka, Mađarska i Turska s tri do osam visokih učilišta, te na samom dnu istočne zemlje i Island s jednim do tri visoka učilišta. Ta skupina uključuje i Hrvatsku, odnosno, jezgra od 234 najpovezanija visoka učilišta uključuje i Sveučilište u Zagrebu.

Tablica 6. Zastupljenost zemalja u jezgri visokih učilišta

Zemlja	Broj visokih učilišta u jezgri	Udio (%)
DE	36	15,38
ES	34	14,53
IT	31	13,25
FR	30	12,82
UK	13	5,55
NL	8	3,42
PL	8	3,42
BE	7	3
PT	7	3
SE	6	2,56
FI	6	2,56
AT	5	2,14
IE	5	2,14
CZ	4	1,71
HU	4	1,71
TR	4	1,71
DK	3	1,28
EL	3	1,28
NO	3	1,28
RO	3	1,28
EE	2	0,85
LT	2	0,85
SI	2	0,85
SK	2	0,85
BG	1	0,43
CY	1	0,43
HR	1	0,43
IS	1	0,43
LV	1	0,43
MT	1	0,43

Samu prisutnost i poziciju pojedinačnih visokih učilišta u mreži mjerili smo putem nekoliko mjera koje nam se nude u mrežnoj analizi. Popularnost čvora u usmjerenoj mreži isto je što i ulazni stupanj, a u našoj mreži mjeri broj različitih institucija s kojih dolaze mobilni studenti i akademsko osoblje. Broj različitih partnera u našem slučaju isto je što i stupanj čvora. Stupanj i ulazni stupanj mogu se značajno razlikovati, s obzirom da je uvjet da partnerstvo između dva visoka učilišta smatramo realiziranim minimalno jedna mobilnost, u bilo kojem smjeru. Pri izračunu broja partnera usmjerene veze smo pretvorili u neusmjerene. Broj dolaznih i odlaznih mobilnosti nam govori u kojoj mjeri visoko učilište sudjeluje u programu. Kako bismo definirali prestiž neposredne blizine čvora u

mreži (eng. *proximity prestige*), bitno je da prvo definiramo ulaznu domenu (eng. *input domain*). Ulazna domena čvora u usmjerenjnoj mreži je „broj ili postotak svih ostalih vrhova koji su povezani putem² do tog čvora“ (De Nooy, Mrvar i Batagelj, 2011, 193). Prestiž neposredne blizine čvora je „omjer svih čvorova (osim samog sebe) u ulaznoj domeni toga čvora, podijeljenih s prosječnom udaljenosti od svih čvorova u toj ulaznoj domeni“ (De Nooy, Mrvar i Batagelj, 2011, 197). Popularnost je ponešto restriktivna mjera prestiža iz razloga što ne uzima u obzir indirektne veze. No, s druge strane u veoma povezanoj mreži ulazna domena čvora može sadržavati gotovo sve druge čvorove, a velika udaljenost između čvorova u domeni tako može značajno sniziti iznos prestiža neposredne blizine, stoga isti nije nužno dobar izvor razlikovanja dobro povezanih čvorova.

Tablica 7. Korelacije mjera prestiža i broja mobilnosti

	Broj različitih partnera (<i>degree</i>)	Popularnost (<i>indegree</i>)	Broj dolaznih mobilnosti (<i>weighted indegree</i>)	Broj odlaznih mobilnosti (<i>weighted outdegree</i>)	Prestiž neposredne blizine (<i>proximity prestige</i>)
Broj različitih partnera (<i>degree</i>)	1	,968**	,866**	,889**	,615**
Popularnost (<i>indegree</i>)	,968**	1	,956**	,907**	,501**
Broj dolaznih mobilnosti (<i>weighted indegree</i>)	,866**	,956**	1	,908**	,410**
Broj odlaznih mobilnosti (<i>weighted outdegree</i>)	,889**	,907**	,908**	1	,411**
Prestiž neposredne blizine (<i>proximity prestige</i>)	,615**	,501**	,410**	,411**	1

** . $p < 0,01$ (dvosmjerno mjerenje)

U Tablici 7. možemo vidjeti povezanosti navedenih mjera prestiža i broja dolaznih i odlaznih mobilnosti. Možemo primijetiti kako su sve korelacije iznimno visoke, uz iznimku umjerene korelacije prestiža neposredne blizine s ostalim mjerama i količinom

² Prema De Nooy, Mrvar i Batagelj (2011) put je šetnja u kojoj se niti jedan čvor između prvog i zadnjeg čvora u šetnji ne pojavljuje više od jednom. Pri tom je šetnja slijed linija od čvora u do čvora v , takav da je krajnji čvor jedne linije početni čvor sljedeće linije i slijed započinje na čvoru u i završava na čvoru v , s dodatnim uvjetom da nijedna od linija u slijedu nije strelica (luk) čiji je krajnji čvor na repu strelice.

ostvarenih mobilnosti. Ovakav rezultat očekivan je s obzirom da mjere prestiža na sličan način mjere poziciju čvora unutar mreže, a za očekivati je da će visoka učilišta koja imaju više partnera, povezanija su i generalno imaju centralniju poziciju u mreži imati i veći broj ostvarenih mobilnosti, bilo dolaznih bilo odlaznih.

U Prilozima možemo vidjeti tablične prikaze dvadeset visokih učilišta s najvećim iznosima za svaku od navedenih mjera. S obzirom na visinu korelacije, ne začuđuje nas da se jedanaest visokih učilišta (vidi Tablicu 8.) pojavljuje među prvih dvadeset u svim mjeranim kategorijama. Valja primijetiti kako je zastupljenost španjolskih visokih učilišta visoka. Naime, od navedenih jedanaest visokih učilišta pet je španjolskih. Ovakvi rezultati u skladu su s rezultatima do kojih su došli Breznik i Gologranc (2014) analizirajući mrežu studentskih mobilnosti u svrhu studija, u okviru Erasmus programa, u razdoblju od 2007./2008. do 2011./2012. akademske godine. Štoviše među navedenih jedanaest visokih učilišta samo se P LISBOA109 i B LEUVEN01 nisu našli na listi dvadeset visokih učilišta s najvećim brojem razmijenjenih studenata u radu Breznik i Gologranc (2014). Iako mreža ne odražava svojstva nesrazmjerne mreže, odnosno ne dolazi do velikog rasta i „bogaćenja bogatih“, visoka učilišta s najvišim strukturnim prestižem uspijevaju zadržati svoje pozicije u mreži.

Tablica 8. Visoka učilišta s najvišim strukturnim prestižem

ERASMUS ID	Popularnost	Broj različitih partnera	Broj dolaznih mobilnosti	Broj odlaznih mobilnosti	Prestiž neposredne blizine
E GRANADA01	570	665	4091	3569	0,4215
SI LJUBLJA01	543	723	2785	2503	0,4323
P LISBOA109	508	752	3310	1905	0,4186
E MADRID03	504	620	3551	3021	0,4171
I BOLOGNA01	478	584	3745	3935	0,4144
E VALENCI02	466	552	2801	2247	0,4161
CZ PRAHA07	464	539	3513	2522	0,41
B LEUVEN01	441	531	2694	2364	0,4093
E BARCELO01	418	503	2412	1931	0,4062
E VALENCI01	414	493	3618	2903	0,407
I ROMA01	396	479	2179	2778	0,4059

Nadalje, u radu smo htjeli ispitati odražava li strukturni prestiž u mreži Erasmus mobilnosti društveni prestiž koji visoka učilišta uživaju. Pregledom *Times Higher Education (THE)* rang ljestvice visokih učilišta u Europi za 2017. godinu, nije teško

primijetiti dominaciju visokih učilišta Ujedinjenog Kraljevstva. Pregledom pak visokih učilišta s najvišim rezultatima na mjerama prestiža i s najvećim brojem ostvarenih mobilnosti, možemo primijetiti dominaciju španjolskih visokih učilišta. Također, top jedanaest visokih učilišta s centralnim pozicijama u mreži ne rangira visoko na Times Higher Education ljestvici. Iako navedena ljestvica uzima u obzir mobilnost pri računanju ranga, ne očekujemo veliku povezanost između strukturnog i društvenog prestiža. U Tablici 9. prikazane su korelacije mjera prestiža visokih učilišta koja se nalaze na ljestvici s rangom i dostupnim indikatorima Times Higher Educationa za 2017. godinu.

Tablica 9. Korelacija mjera strukturnog i društvenog prestiža

	Rang 2017.	Broj studenata	Omjer studenata i profesora	Udio međunarodnih studenata
Broj različitih partnera	,164*	,322**	-,084	-,481**
Popularnost	,071	,339**	-,086	-,409**
Broj dolaznih mobilnosti	-,022	,336**	-,091	-,291**
Broj odlaznih mobilnosti	,071	,357**	-,079	-,336**
Prestiz neposredne blizine	,068	,167*	-,043	-,159*

** . $p < 0,01$. (dvosmjerno mjerenje)

*. $p < 0,05$. (dvosmjerno mjerenje)

Najveća povezanost koju možemo primijetiti je umjerena korelacija od -0,48 između broja različitih partnera i udjela međunarodnih studenata. Negativna korelacija svakako nije bila očekivana, a kao moguće objašnjenje vidimo veću orijentiranost elitnih visokih učilišta na privlačenje studenata mobilnih u svrhu stjecanja kvalifikacije, odnosno studenata koji plaćaju školarinu, nego na privremeno mobilne studente i programsku mobilnost. Nadalje, povezanosti za koje smo očekivali da će biti veće jesu povezanosti broja upisanih studenata s brojem partnera te dolaznim i odlaznim brojem mobilnosti. Očekivali smo da će veličina visokog učilišta utjecati na mjeru kojom sudjeluje u programu.

U skladu s očekivanjem, i našom trećom postavljenom hipotezom, ne postoji povezanost mjera strukturnog prestiža s rangom visokog učilišta, odnosno strukturni prestiž ne odgovara onom društvenom. Tremblay (2008) ističe kako privlačnost elitnih visoko obrazovnih institucija proizlazi iz percipirane društvene mreže koju mogu ponuditi, ali i kontinuiranog prestiža i oskudice kao pozicijske robe. Upravo u tome vidimo dio objašnjenja za nepostojanje ove povezanosti. Naime, visoki rezultati na svim

mjerama kojima se mjeri prestiž u mreži mobilnosti ujedno označavaju i veću dostupnost tih visokih učilišta većem broju studenata. Smatramo stoga da su elitna visoka učilišta više izbirljiva pri sklapanju partnerstava s drugim visokim učilištima. Dio objašnjenja vidimo i u motivaciji samih studenata za odlaskom na mobilnost, s obzirom da nam je poznato kako je percepcija kvalitete prihvatne institucije najrelevantnija za studente na poslijediplomskoj razini (Clarke, 2007). To nas dovodi do posljednje postavljene hipoteze, odnosno očekivanja da će akademsko osoblje biti sklonije odlasku na mobilnost na prestižnija visoka učilišta od studenata. Kao što možemo vidjeti u Tablici 10. Povezanost dolazne mobilnosti akademskog osoblja s rangom visokog učilišta je blaga. No, s druge strane povezanost ne postoji u slučaju studentskih mobilnosti, stoga sukladno očekivanom možemo zaključiti kako su za razliku od studenata profesori ipak motivirani percepcijom kvalitete ili prestiža pri odabiru prihvatne institucije.

Tablica 10. Povezanost prestiža dolazne mobilnosti profesora i studenata

	STA dolazne mobilnosti	SMS dolazne mobilnosti
Rang visokog učilišta	,370**	-,096
Broj studenata	,318**	,316**
Omjer studenata i profesora	-,023	-,098
Udio međunarodnih studenata	-,422**	-,246**

** . $p < 0.01$. (dvosmjerno mjerenje)

* . $p < 0.05$. (dvosmjerno mjerenje)

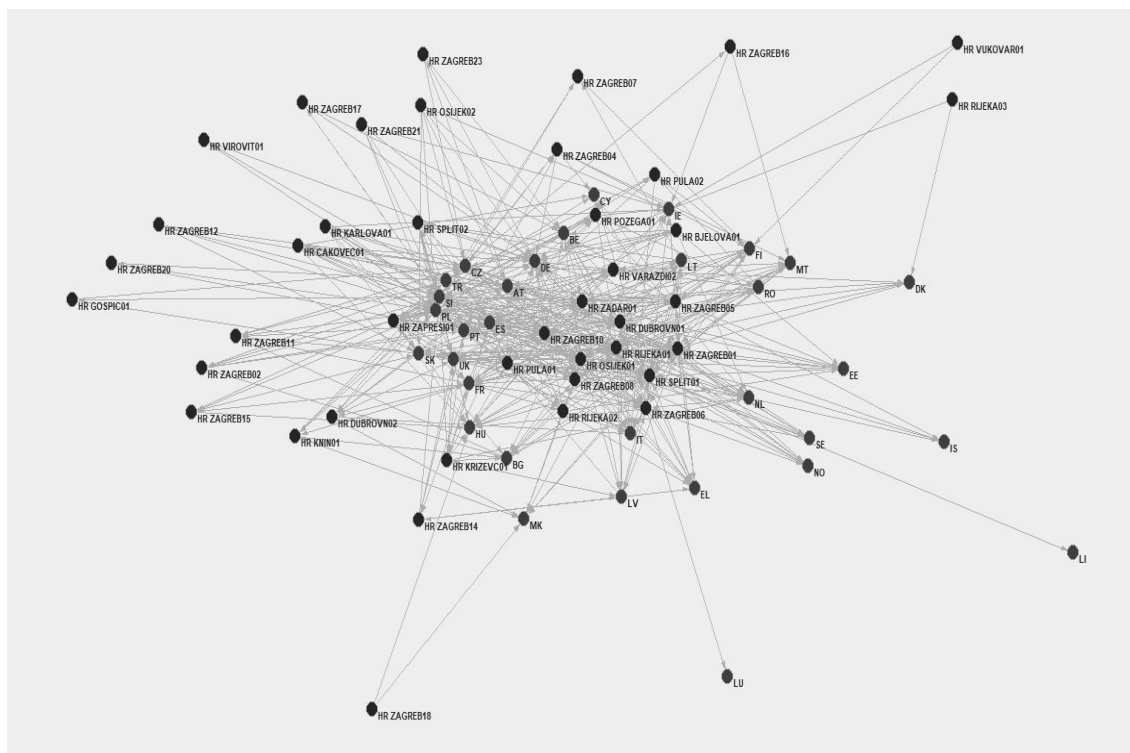
Što se tiče pozicije hrvatskih visokih učilišta u mreži mobilnosti tek Sveučilište u Zagrebu (HR ZAGREB01) ima visok strukturalni prestiž, te se u mjerenju popularnosti, broju različitih partnera i prestižu neposredne blizine nalazi među prvih dvadeset. To nas ne čudi s obzirom da je to jedino hrvatsko visoko učilište koje se nalazi u *k*-jezgri. U Tablici 11. možemo vidjeti rezultate koje ostvaruju najzastupljenijih deset hrvatskih visokih učilišta u mreži³.

³ U Prilozima se. nalazi popis svih ERASMUS ID kodova za hrvatska visoka učilišta.

Tablica 11. Deset hrvatskih visokih učilišta s najvećim strukturalnim prestižem


ERASMUS ID	Broj različitih partnera	Popularnost	Broj dolaznih mobilnosti	Broj odlaznih mobilnosti	Prestiž neposredne blizine
HR ZAGREB01	490	385	1477	1369	0,4124
HR RIJEKA01	156	113	358	290	0,3598
HR SPLIT01	148	113	374	392	0,3708
HR ZADAR01	107	88	251	117	0,3571
HR OSIJEK01	110	50	112	229	0,3431
HR DUBROVN01	61	47	155	58	0,3436
HR ZAGREB06	53	43	169	82	0,3335
HR PULA01	32	26	80	47	0,3241
HR ZAGREB10	29	23	71	44	0,3057
HR ZAPRESI01	17	6	11	29	0,2574

Poziciju hrvatskih visokih učilišta u odnosu jednih spram drugih u mreži Erasmus mobilnosti najbolje ćemo shvatiti iz kontekstualne perspektive. Slika 5. prikazuje takvu perspektivu hrvatskih visokih učilišta u odnosu na zemlje primateljice/pošiljateljice. s obzirom da mobilnosti gledamo na razini odabranog klastera visokih učilišta i razini zemalja, u mrežu su uključeni svi tipovi mobilnosti.



Slika 5. Kontekstualni pogled na mrežu mobilnosti u Hrvatskoj

Na dendogramu hrvatskih visokih učilišta (Slika 6.) bolje se vidi istaknuta pozicija Sveučilišta u Zagrebu, koja je ujedno i očekivana s obzirom da povijesna neravnoteža između davno osnovanog Sveučilišta u Zagrebu i ostalih regionalnih sveučilišta i veleučilišta i dalje karakterizira hrvatsko visoko obrazovanje.



Slika 6. Dendogram hrvatskih visokih učilišta

Jako velika koncentracija visoko obrazovnih institucija i instituta u glavnom gradu, znači i koncentraciju resursa, osoblja i studenata (Duke i dr., 2008, 14). Split i Rijeka predstavljaju veća i starija sveučilišta stoga su uz Zagreb strukturalno najudaljeniji od ostatka. Nadalje su klasterom odvojena manja i mlađa sveučilišta i velika veleučilišta, poput Tehničkog Veleučilišta Zagreb. Iako su odvojeni klasterom, ova visoka učilišta nemaju sličnu strukturalnu poziciju u mreži. Ono što ostatak veleučilišta i visokih škola čini sličnima, gotovo strukturno ekvivalentnima, jest malen broj mobilnosti u programu.

7. Zaključak

Ovim radom željeli smo ispitati topologiju mreže Erasmus+ mobilnosti i prikazati njene strukturne karakteristike, te pružiti točan prikaz trendova i obrazaca četiriju tipova mobilnosti visokih učilišta, kao i ukupne mobilnosti u okviru programa. Proučavanje brojnih velikih mreža koje postoje u svijetu ukazalo je na učestalu prisutnost koncentrata, odnosno čvorova u mreži s jako velikim stupnjem. Rezultat preferencijalnog povezivanja novih čvorova pri rastu mreže dovodi do akumulacije prednosti i sve veće razlike, što rezultira distribucijom stupnja koja prati zakon potencije. To je pak značajna karakteristika nesrazmjerne mreže, a s obzirom na učestalost s kojom se pojavljuje u stvarnom svijetu, očekivali smo da će naša mreža odražavati to svojstvo. Tu smo hipotezu morali odbaciti s obzirom da distribucija broja partnera visokih učilišta u mreži SMS i STA mobilnosti značajno odstupa od svih tipova distribucija ponuđenih softverom za testiranje. Naši rezultati odstupaju i od rezultata dobivenih na istraživanju mreže Erasmus studentskih mobilnosti u svrhu studijskog boravka iz 2003/2004. akademske godine, koji ukazuju na eksponencijalnu distribuciju. Razlog te diskrepancije vjerojatno leži u tome što naša mreža uključuje dva tipa mobilnosti, vremensko razdoblje koje obuhvaća tri natječajne godine, koje je uz to i više od deset godina kasnije. Razlog odstupanja naše distribucije stupnja od eksponencijalne, ali i od distribucije funkcije potencije, može se kriti upravo u aspektu rasta nesrazmjerne mreže. Naime, s obzirom da je broj visokih učilišta koja mogu sudjelovati u programu ograničen, sama mreža je ograničena u svom rastu. To znači da visoka učilišta koja su već dobro povezana ne mogu stjecati velik broj novih partnera velikom brzinom. To pak daje vremena manje povezanim visokim učilištima da se bolje povežu i smanje razliku u broju partnera, zbog čega se naši rezultati vjerojatno razlikuju od rezultata do kojih su došli Derzsi i suradnici

(2011). Kako bismo ispitali ovu pretpostavku nužno je sagledati distribuciju stupnja u mreži Erasmus mobilnosti kroz vrijeme, što u ovom istraživanju nije bilo moguće.

Nadalje, temeljem prethodno prezentirane literature formulirali smo očekivanje da će struktura mreže Erasmus + mobilnosti na razini zemalja odražavati strukturu jezgra/periferija. Matrični prikaz apsolutnog broj ostvarenih mobilnosti ukazuje na to da ne dolazi do promjene u odnosu na prethodne godine po pitanju dominacije pet zemalja: Njemačke, Francuske, Španjolske, Ujedinjenog Kraljevstva i Italije. Te zemlje, ne samo da su najatraktivnije destinacije, već i među sobom dijele najveći broj studenata i akademskog osoblja koji sudjeluje u Erasmus programu. Koncentracija najvećeg broja mobilnosti, odnosno najsnažnijih veza između tih zemalja čini ih jezgrom mreže. Prisutnost nešto slabijih veza sa semiperiferijom u semiperiferiji, te prisutnost jako slabih veza u periferiji i između periferije i semiperiferije odražava strukturu jezgra -periferija. To rezultira koncentracijom veza na horizontalnoj i vertikalnoj traci povezanoj s jezgrom, i potvrđuje našu drugu hipotezu. Na samoj periferiji nalaze se strukturalno najslabije i najmanje zemlje koje ne čine velik udio u ukupnoj mobilnosti programa, uključujući i Hrvatsku.

Akadske razmjene obično se vode načelom reciprociteta, pa tako i Erasmus program. No, unatoč idealu o uravnoteženosti, kojim se vodi Erasmus program, tek šest zemalja, uključujući i Hrvatsku, ima ujednačene tokove dolaznih i odlaznih mobilnosti. Srednjoistočne i jugoistočne zemlje većinom su izvoznice, dok su zapadne zemlje većinom uvoznice. Omjer centraliteta žarišta i autoriteta daje nam istu podjelu zemalja na uvoznice i izvoznice, no valja primijetiti kako da dolazi do nesrazmjera u vrijednostima. Odnosno, najveći izvoznici i uvoznici nisu nužno i „najbolji“. Usporedba omjera Erasmus studentske mobilnosti u svrhu studijskog boravka s podacima o mobilnosti u svrhu stjecanja kvalifikacije upućuje na zaključak da je program, vodeći se idealom reciprociteta, relativno uspješan u kontroliranju razlike između odljeva i priljeva studenata. Vremenski odmak mogao bi objasniti i zašto su tokovi u SMP i STT tipu mobilnosti, koji su u program uvedeni tek 2007. godine, manje uravnoteženi.

S obzirom na količinu podataka i nemogućnost usustavljenja naziva poduzeća koja sudjeluju u programu, na razini institucija analizirali samo mrežu studentskih mobilnosti u svrhu studijskog boravka i mobilnosti akademskog osoblja u svrhu podučavanja. Najpovezaniju komponentu grafa, a time i klaster najpovezanijih visokih učilišta dobili smo preko *k*-jezgre. Jezgru sa minimalnim stupnjem 131 čini 61,54% visokih učilišta iz zemalja jezgre mreže. Razinu sudjelovanja u mreži mjerili

smo brojem ukupnih dolaznih i odlaznih mobilnosti, a samu poziciju i centralnost pojedinih visokih učilišta mjerili smo dostupnim mjerama prestiža koje nudi mrežna analiza – popularnost, broj različitih partnera i prestiž neposredne blizine. Naše očekivanje o najcentralnijim visokim učilištima ogleda se u hipotezi koja kaže da strukturni prestiž visokih učilišta u mreži ne odgovara društvenom prestižu koji visoka učilišta uživaju u društvu. Lista strukturalno najcentralnijih visokih učilišta gotovo je ista kao u istraživanju provedenom na mreži Erasmus studentskih mobilnosti u svrhu studijskog boravka, u razdoblju od 2007./2008. do 2011./2012. akademske godine (Breznik i Gologranc, 2014). To pak vodi do zaključka da iako mreža ne odražava svojstva nesrazmjerne mreže, odnosno ne dolazi do velikog rasta i „bogaćenja bogatih“, visoka učilišta s najvišim strukturnim prestižem uspijevaju zadržati svoje pozicije u mreži, a zastupljenost španjolskih visokih učilišta na toj listi je iznimno visoka. Ipak, u skladu s očekivanjem, ne postoji povezanost mjera strukturnog prestiža s rangom visokog učilišta, odnosno strukturni prestiž ne odgovara onom društvenom. Prema Tremblayu (2008), privlačnost elitnih visoko obrazovnih institucija proizlazi dijelom iz kontinuiranog prestiža i oskudice kao pozicijske robe, a mi upravo u tome vidimo dio objašnjenja za nepostojanje ove povezanosti. Visok strukturalni prestiž znači veliku povezanost i dostupnost tih visokih učilišta većem broju studenata. Smatramo stoga da su elitna visoka učilišta više izbirljiva pri sklapanju partnerstava s drugim visokim učilištima. Dio objašnjenja vidimo i u motivaciji samih studenata za odlaskom na mobilnost, s obzirom da nam je poznato kako je percepcija kvalitete prihvatne institucije najrelevantnija za studente na poslijediplomskoj razini (Clarke, 2007). Time smo došli do posljednje postavljene hipoteze, odnosno očekivanja da će akademsko osoblje biti sklonije odlasku na mobilnost na prestižnija visoka učilišta od studenata. Povezanost dolazne mobilnosti akademskog osoblja s rangom visokog učilišta je malena (0,37). No, s druge strane u slučaju studentskih mobilnosti uopće nema povezanosti, stoga sukladno očekivanom možemo zaključiti kako su za razliku od studenata profesori ipak donekle motivirani percepcijom kvalitete ili prestiža pri odabiru prihvatne institucije.

Literatura

- Barabási, A.L. i Albert, R. (1999). Emergence of Scaling in Random Networks. *Science* 286 1): 509–512.
- Bode, C. i Davidson, M. (2011) International Student Mobility: A European Perspective from Germany and the United Kingdom. U: Bhandari , R. i Blumenthal, P. (ur.) *International Students and Global Mobility in Higher Education: National trends and new directions*. Palgrave Macmillan US.
- Breznik, K. i Gologranc, G. (2014). Erasmus Mobility on the Institutional Level, *Management, Knowledge and Learning International Conference 2013*, Portorož, Slovenija, 25-27 lipnja 2014. Celje: ToKnowPress.
- Breznik, K.; Skbinjek, V.; Law, K. i Đaković, G. (2013). On the Erasmus Student Mobility for Studies, *Management, Knowledge and Learning International Conference 2013*, Zadar, Hrvatska, 19-21 srpnja 2013. Bangkok; Celje; Lublin: ToKnowPress.
- Clarke, M. (2007). The Impact of Higher Education Rangings on student Access, Choice, and Opportunity, *Higher Education in Europe*, 32(1): 59-70.
- De Nooy, W., Mrvar, A., & Batagelj, V. (2011). *Exploratory social network analysis with Pajek*. Cambridge University Press.
- Deakin, H. (2014) The drivers to Erasmus work placement mobility for UK students. *Children's Geographies*, 12(1): 25-39.
- Derzsi, A.; Derzsy, N.; Káptalan, E. i Néda, Z. (2011). Topology of the Erasmus student mobility network. *Physica A*. 390(1): 2601-2610.
- Duke, C.; Hasan, A.; Cappon, P.; Meissner, W.; Metcalf, H. i Thornhill, D. (2008) *OECD Reviews of Tertiary Education: Croatia*. OECD Publishing.
- European Commission (2010). *Communication from the European Commission: Europe 2020. A strategy for smart, sustainable and inclusive. growth*, 3 of March, 2010. European Commission.
- European Commission (2012). *Erasmus – Changing lives, opening minds for 25 years*. Luxembourg: Publication Office of the European Union.
- European Commission (2015). *Erasmus – Facts, Figures & Trends. The European Union support for student and staff exchanges and university cooperation in 2013-14*. Luxembourg: Publication Office of the European Union.
- Fahey, J. i Kenway, J. (2010) International academic mobility: problematic and possible paradigms. *Discourse: Studies in the cultural politics of education*, 31(5): 563-575.
- Ferencz, I. (2011) Credit mobility in EU Programmes ERASMUS and LEONARDO da VINCI. U: Teichler, U., Ferencz, I. i Wächter, B. (ur.), *Mapping mobility in European higher education. Volume I: Overview and trends*. Brussels: European Commission.

- González, C. R., Mesanza, R. B. i Mariel, P. (2011) The determinants of international student mobility flows: an empirical study on the Erasmus programme. *Higher Education*, 62(4): 413-430.
- Hanneman, R. A. i Riddle, M. (2005). *Introduction to social network methods*. Riverside, CA: University of California. (objavljeno u digitalnom obliku, dostupno na: <http://faculty.ucr.edu/~hanneman/>)
- Janson, K.; Schomburg, H. i Teichler, U. (2009) *The Professional Value of ERASMUS Mobility. The Impact of International Experience on Former Students' and on Teachers' Careers*. Bonn: Lemmens.
- Jiang, K. (2014) International student flows between Asia, Australia, and Russia: a network analysis. *Journal of Contemporary Eastern Asia*, 13(1): 83-98.
- Kleinberg J. (1998) Authoritative sources in a hyperlinked environment. In Proc 9th ACM/IEEE Symposium on Discrete Algorithms, p. 668-677.
- Kondakci, Y.; Bedenlier, S. i Zawacki-Richter, O. (2017). Social network analysis of international student mobility: uncovering the rise of regional hubs. *Higher Education*, 1-19.
- Maggioni, M. A. i Uberti, T. E. (2009) Knowledge networks across Europe: which distance matters?. *The Annals of Regional Science*, 43(3): 691-720.
- Marginson, S. i van der Wende, M. (2009) Europeanisation, International Rankings and Faculty Mobility: Three Cases in Higher Education Globalisation. U: OECD (ur.), *Higher Education to 2030, Volume 2, Globalisation*, Paris: OECD Publishing.
- Rodrigues, M. (2012) Determinants and impacts of student mobility: A literature review. *JRC Scientific and Technical Report JRC, 70059*.
- Rostan, M. i Höhle, E. A. (2014) The international mobility of faculty. U: Huang, F.; Finkelstein, M. i Rostan, M. (ur.), *The internationalization of the Academy: Changes, Realities and Prospects*. Dordrecht: Springer.
- Shields, R. (2013) Globalization and international student mobility: A network analysis. *Comparative Education Review*, 57(4): 609-636.
- Shields, R. (2014) Reconsidering regionalisation in global higher education: student mobility spaces of the European Higher Education Area. *Compare: A Journal of Comparative and International Education*. URL: <http://dx.doi.org/10.1080/03057925.2014.8843.48> (19.1.2017.)
- Souto-Otero, M., Huisman, J., Beerkens, M., De Wit, H. i Vujić, S. (2013) Barriers to international student mobility: Evidence from the Erasmus program. *Educational Researcher*, 42(2): 70-77.
- Teichler, U. (2011) Academic staff mobility. U: Teichler, U., Ferencz, I. i Wächter, B. (ur.), *Mapping mobility in European higher education. Volume I: Overview and trends*. Brussels: European Commission.
- Teichler, U. (2015) Academic mobility and migration: what we know and what we do not know. *European Review*, 23(S1): S6-S37.

- Teichler, U. i Janson, K. (2007) The Professional Value of Temporary Study in Another European Country: Employment and Work of Former ERASMUS Students. *Journal of Studies in International Education*. 11(3): 486-495.
- Tremblay, K. (2008) Internationalisation: Shaping Strategies in the National Context. U: Santiago, P.; Tremblay, K.; Basri, E. i Arnal, E. (ur.), *Tertiary Education in the Knowledge Society. Vol. 2: Special Features: Equity, Innovation, Labour Market, Internationalisation*. Paris: OECD.
- Usher, A i Savino, M. (2007). A Global Survey of University Ranking and League Tables. *Higher Education in Europe*, 32(1): 5-15.
- Van der Wende, M. (2015) International Academic Mobility: Towards a Concentration of the Minds in Europe. *European Review*, 23(S1): S70-S88.
- Van Hoof, H.B. i Verbeteen, M.J. (2005). Wine Is for Drinking, Water Is for Washing: Student Opinions About International Exchange Programs. *Journal of Studies in International Education*, 9(1): 42-61.
- Van Mol, C. (2014) *Intra-European Student Mobility in International Higher Education Circuits*. Hampshire: Palgrave Macmillan.
- Wächter, B. i Wuttig, S. (2011) Student mobility in European programmes. U: Teichler, U.; Ferencz, I. i Wächter, B. (ur.), *Mapping Mobility in Higher Education in Europe*. Bonn: Deutscher Akademischer Austausch Dienst.
- Wasserman, S. i Faust, K. (1994). *Social Network Analysis: Methods and Applications*. Cambridge: Cambridge University Press.

Prilozi

Prilog 1. Popis ERASMUS + kodova za hrvatska visoka učilišta

HR BJELOVA01	Visoka tehnička škola u Bjelovaru
HR CAKOVEC01	Međimursko veleučilište u Čakovcu
HR DUBROVN01	Sveučilište u Dubrovniku
HR DUBROVN02	Rit Croatia
HR DUBROVN03	Dubrovnik International University (DIU)
HR GOSPIC01	Veleučilište Nikola Tesla u Gospiću
HR KARLOVA01	Veleučilište u Karlovcu
HR KNIN01	Veleučilište Marko Marulić
HR KRAPINA01	Veleučilište Hrvatsko zagorje Krapina
HR KRIZEVC01	Visoko gospodarsko učilište u Križevcima
HR OSIJEK01	Sveučilište Josipa Jurja Strossmayera u Osijeku
HR OSIJEK02	Veleučilište u Slavonskom Brodu
HR POZEGA01	Veleučilište u Požegi
HR PULA01	Sveučilište Jurja Dobrile u Puli
HR PULA02	Politehnika Pula Visoka tehničko-poslovna škola
HR RIJEKA01	Sveučilište u Rijeci
HR RIJEKA02	Veleučilište u Rijeci
HR RIJEKA03	Visoka poslovna škola Par
HR SIBENIK01	Veleučilište u Šibeniku
HR SPLIT01	Sveučilište u Splitu
HR SPLIT02	Visoka škola za menadžment i dizajn Aspira
HR SPLIT04	Visoka škola za inspektijski i kadrovski menadžment Split
HR SPLIT05	TV-AKADEMIJA Visoka škola multimedijских i komunikacijskih tehnologija
HR VARAZDI02	Sveučilište Sjever
HR VIROVIT01	Visoka škola za menadžment u turizmu i informatici u Virovitici
HR VUKOVAR01	Veleučilište Lavoslav Ružička u Vukovaru
HR ZADAR01	Sveučilište u Zadru
HR ZAGREB01	Sveučilište u Zagrebu
HR ZAGREB02	Rrif Visoka škola za financijski menadžment
HR ZAGREB04	Zdravstveno veleučilište
HR ZAGREB05	Tehničko veleučilište u Zagrebu
HR ZAGREB06	Zagrebačka škola ekonomije i managementa
HR ZAGREB07	Visoka škola Nikola Šubić Zrinski
HR ZAGREB08	Veleučilište Velika Gorica
HR ZAGREB10	Veleučilište Vern
HR ZAGREB11	Visoko učilište Algebra - Visoka škola za primijenjeno računarstvo
HR ZAGREB12	Visoko učilište Effectus-visoka škola za financije i pravo
HR ZAGREB14	Visoka poslovna škola Libertas
HR ZAGREB15	Hrvatsko katoličko sveučilište
HR ZAGREB16	Visoka škola za informacijske tehnologije
HR ZAGREB17	Visoka škola tržišnih komunikacija Agora
HR ZAGREB18	Visoka škola međunarodnih odnosa i diplomacije DagHammarskjöld
HR ZAGREB20	Visoka škola za sigurnost s pravom javnosti
HR ZAGREB21	Visoka poslovna škola Zagreb s pravom javnosti
HR ZAGREB23	Edward Bernays Visoka škola za komunikacijski menadžment

HR ZAGREB24
HR ZAPRESI01

Policijska akademija
Veleučilište Baltazar Zaprešić

Prilog 2 . 20 visokih učilišta s najvećim brojem partnera

ERASMUS ID	Broj različitih partnera (<i>degree</i>)
SI LJUBLJA01	723
E GRANADA01	665
E MADRID03	620
I BOLOGNA01	584
P LISBOA109	572
E VALENCI02	552
CZ PRAHA07	539
B LEUVEN01	531
E BARCELO01	503
E VALENCI01	493
HR ZAGREB01	490
I ROMA01	479
E BILBAO01	479
P PORTO02	477
I PADOVA01	462
E BARCELO02	459
E ZARAGOZ01	451
CZ BRNO05	438
E MALAGA01	437
E SEVILLA01	430

Prilog 3 . 20 najpopularnijih visokih učilišta

ERASMUS ID	Popularnost (incoming degree)
E GRANADA01	570
SI LJUBLJA01	543
P LISBOA109	508
E MADRID03	504
I BOLOGNA01	478
E VALENCI02	466
CZ PRAHA07	464
B LEUVEN01	441
E BARCELO01	418
E VALENCI01	414
I ROMA01	396
P PORTO02	393
HR ZAGREB01	385
E MALAGA01	378
E BARCELO02	376
I FIRENZE01	359
I PADOVA01	347
E SALAMAN02	346
E SEVILLA01	345

Prilog 4. 20 visokih učilišta s najvećim prestižem neposredne blizine

ERASMUS ID	Neposredni prestiž (<i>proximity prestige</i>)
SI LJUBLJA01	0,4323
E GRANADA01	0,4215
P LISBOA109	0,4186
E MADRID03	0,4171
E VALENCI02	0,4161
I BOLOGNA01	0,4144
HR ZAGREB01	0,4124
CZ PRAHA07	0,41
B LEUVEN01	0,4093
E VALENCI01	0,407
E BARCELO01	0,4062
I ROMA01	0,4059
E BARCELO02	0,4056
P PORTO02	0,4052
PL KRAKOW01	0,4013
PL WARSZAW01	0,4
B GENT01	0,3995
E MALAGA01	0,3988
E BARCELO03	0,3977

Prilog 5. 20 visokih učilišta s najvećim brojem dolaznih mobilnosti u SMS i STA mreži

ERASMUS ID	Broj dolaznih mobilnosti (<i>weighted indegree</i>)
E GRANADA01	4091
I BOLOGNA01	3745
E VALENCI01	3618
E MADRID03	3551
CZ PRAHA07	3513
P LISBOA109	3310
E VALENCI02	2801
SI LJUBLJA01	2785
B LEUVEN01	2694
E BARCELO01	2412
E SEVILLA01	2269
A WIEN01	2193
I ROMA01	2179
E MALAGA01	2019
P PORTO02	2014
E BARCELO03	2000
I MILANO02	1960
N TRONDHE01	1950
E SALAMAN02	1927

Prilog 6. 20 visokih učilišta s najvećim brojem odlaznih mobilnosti u SMS i STA mreži

ERA ID	Broj odlaznih mobilnosti (<i>weighted outdegree</i>)
I BOLOGNA01	3935
E GRANADA01	3569
E MADRID03	3021
E VALENCI01	2903
I PADOVA01	2830
I ROMA01	2778
CZ PRAHA07	2522
SI LJUBLJA01	2503
PL WARSZAW01	2457
B LEUVEN01	2364
CZ BRNO05	2322
A WIEN01	2307
E VALENCI02	2247
E BILBAO01	2222
E BARCELO03	2192
E BARCELO01	1931
E ZARAGOZ01	1926
E MADRID05	1909
P LISBOA109	1905

Prilog 7. Mjere prestiža za hrvatska visoka učilišta u mreži SMS i STA mobilnosti

ERASMUS ID	Broj različitih partnera	Popularnost (<i>incoming degree</i>)	Broj dolaznih mobilnosti	Broj odlaznih mobilnosti	Neposredni prestiž
HR ZAGREB01	490	385	1477	1369	0,4124
HR RIJEKA01	156	113	358	290	0,3598
HR SPLIT01	148	113	374	392	0,3708
HR ZADAR01	107	88	251	117	0,3571
HR OSIJEK01	110	50	112	229	0,3431
HR DUBROVN01	61	47	155	58	0,3436
HR ZAGREB06	53	43	169	82	0,3335
HR PULA01	32	26	80	47	0,3241
HR ZAGREB10	29	23	71	44	0,3057
HR ZAPRESI01	17	6	11	29	0,2574
HR ZAGREB05	14	7	35	39	0,3005
HR ZAGREB11	13	13	26	2	0,284
HR CAKOVEC01	11	5	8	20	0,2848
HR SPLIT02	11	11	23	2	0,2876
HR VARAZDI02	11	7	17	9	0,2725
HR ZAGREB08	10	7	17	5	0,2923
HR RIJEKA02	10	9	28	3	0,3005
HR ZAGREB02	7	5	6	3	0,2427
HR KNIN01	6	3	6	11	0,2449
HR KRIZEVC01	6	2	2	5	0,2567
HR PULA02	5	5	12	2	0,2491
HR ZAGREB04	5	5	11	3	0,2962
HR BJELOVA01	5	1	2	6	0,2645
HR DUBROVN02	5	3	4	4	0,2739
HR POZEGA01	6	4	5	5	0,2534
HR VIROVIT01	5	3	4	9	0,1989
HR ZAGREB14	5	4	17	4	0,2833
HR ZAGREB15	5	3	6	7	0,294
HR KARLOVA01	4	2	8	4	0,2185
HR ZAGREB12	5	1	2	5	0,2464
HR ZAGREB20	3	2	4	4	0,2552
HR ZAGREB07	3	1	3	2	0,238
HR ZAGREB18	3	0	0	5	0
HR GOSPIC01	2	1	1	1	0,0003
HR ZAGREB17	2	1	1	2	0,2497
HR ZAGREB23	2	1	1	1	0,2338
HR RIJEKA03	1	0	0	1	0
HR ZAGREB16	1	1	1	0	0,1695
HR ZAGREB21	1	0	0	2	0

Sažetak

U radu je analizirana mreža mobilnosti u okviru Erasmus+ programa. Na razini zemalja sagledali smo mrežu ukupne mobilnosti u programu. Uz očiglednu dominaciju pet zemalja (Njemačke, Francuske, Španjolske, Ujedinjenog Kraljevstva i Italije) struktura mreže odražava strukturu jezgra-periferija. Analiza tokova dolaznih i odlaznih mobilnosti upućuje na zaključak da je program relativno uspješan u kontroli razlike između priljeva i odljeva. Ipak, neuravnoteženost kod nekih zemalja poprima ekstremne vrijednosti. Pri tome centralitet autoriteta i žarišta ukazuje kako najveći izvoznici i uvoznici nisu nužno i „najbolji“.

Radom smo nadalje sagledali mrežu studentskih mobilnosti u svrhu studijskog boravka i mobilnosti akademskog osoblja u svrhu podučavanja na razini institucija. Distribucija stupnja značajno odstupa od distribucije funkcije potencije i eksponencijalne distribucije, odnosno sama mreža se ne uklapa u nesrazmjerni model. Iako ne dolazi do velikog rasta i „bogaćenja bogatih“, visoka učilišta s najvišim strukturnim prestižem uspijevaju zadržati svoje pozicije u mreži, a zastupljenost španjolskih visokih učilišta na toj listi je iznimno visoka. Sam strukturni prestiž ne odražava onaj društveni, koji djelomično proizlazi upravo iz nedostupnosti većem broju studenata. Ipak, za razliku od studenata profesori su donekle motivirani percepcijom prestiža visokog učilišta pri odabiru prihvatne institucije.

Ključne riječi: *mrežna analiza, Erasmus+, mobilnost, visoka učilišta*

Abstract

This paper analyzes the mobility network within the Erasmus + program. At the country level, we analyzed the network of total mobility within the program. Along with the visible dominance of five countries (Germany, France, Spain, United Kingdom and Italy), the network structure reflects the core-periphery structure. Analysis of the incoming and outgoing mobility flows indicates that the program is relatively successful in controlling the difference between inflows and outflows. Nevertheless, the imbalance in some countries has extreme values. Thereat, authorities and hubs centrality indicates that the biggest exporters and importers are not necessarily the "best" ones too.

Furthermore we analyzed the network of student mobility for studies and staff mobility for teaching at the institutional level. Degree distribution significantly deviates from the power law distribution and exponential distribution, i.e. the network itself does not fit into a scale-free model. Even though there is no large growth and "rich get richer" effect, higher education institutions with the highest structural prestige maintain their positions in the network, with the exceptionally high representation of Spanish higher education institution on this list. Structural prestige itself does not reflect social prestige, which partly derives from the inaccessibility to a greater number of students. However, unlike the students, the professors are somewhat motivated by the perception of the prestige of the higher education institution when choosing a receiving institution.

Key words: *social network, Erasmus+, mobility, higher education institutions*